


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**
ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

ANALÝZA AVG SIGNÁLŮ

THE ANALYSIS OF AVG SIGNALS

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. Václav Musil

VEDOUCÍ PRÁCE
SUPERVISOR

doc. Ing. Jiří ROZMAN, CSc.

BRNO, 2008

ZADÁNÍ

BIBLIOGRAFICKÁ CITACE

MUSIL, V. *Analýza AVG signálů*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2008. 68 s. Vedoucí diplomové práce doc. Ing. Jiří Rozman, CSc.

LICENČNÍ SMLOUVA

POSKYTOVANÁ K VÝKONU PRÁVA UŽÍT ŠKOLNÍ DÍLO

uzavřená mezi smluvními stranami:

1. Pan/paní

Jméno a příjmení: Václav Musil
Bytem: Příkopy 1237, Kostelec nad Orlicí, 517 41
Narozen/a (datum a místo): 21. listopadu 1983 v Hradci Králové

(dále jen „autor“)

a

2. Vysoké učení technické v Brně

Fakulta elektrotechniky a komunikačních technologií
se sídlem Údolní 53, Brno, 602 00
jejímž jménem jedná na základě písemného pověření děkanem fakulty:
prof. Ing. Jiří Jan, CSc., předseda rady oboru Biomedicínské a ekologické inženýrství
(dále jen „nabyvatel“)

Čl. 1

Specifikace školního díla

1. Předmětem této smlouvy je vysokoškolská kvalifikační práce (VŠKP):

- ☐ disertační práce
 - ☒ diplomová práce
 - ☐ bakalářská práce
 - ☐ jiná práce, jejíž druh je specifikován jako
- (dále jen VŠKP nebo dílo)

Název VŠKP: Analýza AVG signálů
Vedoucí/ školitel VŠKP: doc. Ing. Jiří Rozman, CSc.
Ústav: Ústav biomedicínského inženýrství
Datum obhajoby VŠKP: _____

VŠKP odevzdal autor nabyvateli*:

- ☒ v tištěné formě – počet exemplářů: 2
- ☒ v elektronické formě – počet exemplářů: 2

2. Autor prohlašuje, že vytvořil samostatnou vlastní tvůrčí činností dílo shora popsané a specifikované. Autor dále prohlašuje, že při zpracovávání díla se sám nedostal do rozporu s autorským zákonem a předpisy souvisejícími a že je dílo dílem původním.
3. Dílo je chráněno jako dílo dle autorského zákona v platném znění.
4. Autor potvrzuje, že listinná a elektronická verze díla je identická.

* hodící se zaškrtněte

Článek 2

Udělení licenčního oprávnění

1. Autor touto smlouvou poskytuje nabyvateli oprávnění (licenci) k výkonu práva uvedené dílo nevýdělečně užít, archivovat a zpřístupnit ke studijním, výukovým a výzkumným účelům včetně pořizování výpisů, opisů a rozmnoženin.
2. Licence je poskytována celosvětově, pro celou dobu trvání autorských a majetkových práv k dílu.
3. Autor souhlasí se zveřejněním díla v databázi přístupné v mezinárodní síti
 - ☒ ihned po uzavření této smlouvy
 - ☐ 1 rok po uzavření této smlouvy
 - ☐ 3 roky po uzavření této smlouvy
 - ☐ 5 let po uzavření této smlouvy
 - ☐ 10 let po uzavření této smlouvy(z důvodu utajení v něm obsažených informací)
4. Nevýdělečné zveřejňování díla nabyvatelem v souladu s ustanovením § 47b zákona č. 111/ 1998 Sb., v platném znění, nevyžaduje licenci a nabyvatel je k němu povinen a oprávněn ze zákona.

Článek 3

Závěrečná ustanovení

1. Smlouva je sepsána ve třech vyhotoveních s platností originálu, přičemž po jednom vyhotovení obdrží autor a nabyvatel, další vyhotovení je vloženo do VŠKP.
2. Vztahy mezi smluvními stranami vzniklé a neupravené touto smlouvou se řídí autorským zákonem, občanským zákoníkem, vysokoškolským zákonem, zákonem o archivnictví, v platném znění a popř. dalšími právními předpisy.
3. Licenční smlouva byla uzavřena na základě svobodné a pravé vůle smluvních stran, s plným porozuměním jejímu textu i důsledkům, nikoliv v tísní a za nápadně nevýhodných podmínek.
4. Licenční smlouva nabývá platnosti a účinnosti dnem jejího podpisu oběma smluvními stranami.

V Brně dne: 30. května 2008

.....
Nabyvatel

.....
Autor

ANOTACE

Předkládaná diplomová práce se zabývá vybranými metodami analýzy AVG signálů. Cílem této práce je klasifikace těchto signálů a tím přispění k možnostem neinvazivní diagnostiky ischemické choroby dolních končetin. K tomu je využito klasifikace založené na principech vícerozměrné statistické analýzy a na postupech využívajících neuronové sítě.

Ke zpracování je použita angiograficky ověřená databáze dat AVG signálů. V závislosti na stupni stenózy, určené digitální subtrakční angiografií, jsou pacienti v tomto souboru roztrženi do tří separovatelných tříd. Na programové klasifikaci do jedné ze tří tříd se podílí 6 parametrů určených z AVG signálů, které byly pořízeny na třech místech měření dolní končetiny. Jako komplexní se jeví přístup k hodnocení choroby ze signálů naměřených na celé dolní končetině.

Senzitivita metody shlukové analýzy vzhledem k angiografii se pohybuje v rozmezí 82,75 % až 90,90 %, specificita pak mezi 80,66 % a 88,88 %. Při klasifikaci neuronovými sítěmi jsou hodnoty senzitivity v rozmezí 79,06 % až 96,87 % a hodnoty specificity mezi 73,07 % a 91,30 %.

KLÍČOVÁ SLOVA

Arteriovelocitogram, AVG, Dopplerův jev, hlavní komponenty, ischemická choroba dolních končetin, neuronové sítě, shluková analýza, umělý neuron, vícerozměrné statistické metody.

ABSTRACT

The presented thesis discusses the basic analysis methods of arteriovelocitograms. The core of this work rests in classification of signals and contribution to possibilities of noninvasive diagnostic methods for evaluation patients with peripheral ischemic occlusive arterial disease. The classification employs multivariate statistical methods and principles of neural networks.

The data processing works with an angiographic verified set of arteriovelocitogram dates. The digital subtraction angiography classified them into 3 separable classes in dependence on degree of vascular stenosis. Classification AVG signals are represented in the program by the 6 parameters that are measured on 3 different places on each patient's leg. Evaluation of disease appeared to be a comprehensive approach at signals acquired from whole patient's leg.

The sensitivity of clustering method compared with angiography is between 82.75 % and 90.90 %, specificity between 80.66 % and 88.88 %. Using neural networks sensitivity is in range of 79.06 % and 96.87 %, specificity is in range of 73.07 % and 91.30 %.

KEYWORDS

Arteriovelocitogram, AVG, Artificial Neuron, Artificial Neural Networks, Cluster Analysis, Doppler effect, Multivariate Statistical Methods, Peripheral Ischemic Occlusive Arterial Disease, Principals Components.

Prohlášení

Prohlašuji, že svou diplomovou práci na téma Analýza AVG signálů jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne 30. května 2008

.....
podpis autora

Poděkování

Děkuji vedoucímu diplomové práce doc. Ing. Jiřímu Rozmanovi, CSc. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne 30. května 2008

.....
podpis autora

OBSAH

1. ÚVOD DO PROBLEMATIKY	10
2. METODIKA SNÍMÁNÍ AVG SIGNÁLŮ.....	11
2.1. REOLOGICKÉ VLASTNOSTI KRVÉ A SNÍMANÝ AVG SIGNÁL	11
2.2. PRINCIP DOPPLEROVA JEVU, PRINCIP SNÍMÁNÍ SIGNÁLŮ	12
2.3. DIAGNOSTICKÝ SYSTÉM IMEXLAB 9000	13
2.4. DATABÁZE AVG	14
3. ANALÝZA AVG SIGNÁLŮ.....	15
3.1. PARAMETRY AVG SIGNÁLU - DEFINICE.....	15
3.2. PŘEHLED A SHRUTÍ METOD ANALÝZY	16
3.2.1. <i>Hodnocení tvaru signálu.....</i>	<i>17</i>
3.2.2. <i>Hodnocení spektra dopplerovského signálu.....</i>	<i>17</i>
3.2.3. <i>Identifikační analýza.....</i>	<i>18</i>
3.2.4. <i>Vícerozměrné statistické metody.....</i>	<i>18</i>
3.2.5. <i>Klasifikace expertními systémy a neuronovými sítěmi</i>	<i>19</i>
4. ZVOLENÉ METODY ŘEŠENÍ	20
4.1. VYUŽITÍ VÍCEROZMĚRNÝCH STATISTICKÝCH METOD	20
4.1.1. <i>Ověření normality - test šikmosti a špičatosti</i>	<i>20</i>
4.1.2. <i>Grubbsův test extrémních odchylek</i>	<i>22</i>
4.1.3. <i>Redukce počtu dat pomocí metody hlavních komponent</i>	<i>22</i>
4.1.4. <i>Shluková analýza</i>	<i>23</i>
4.2. VYUŽITÍ NEURONOVÝCH SÍTÍ	24
4.2.1. <i>Úvod do problematiky neuronových sítí</i>	<i>24</i>
4.2.2. <i>Biologický model neuronu</i>	<i>24</i>
4.2.3. <i>Základní model umělého neuronu</i>	<i>25</i>
4.2.4. <i>Struktura neuronové sítě</i>	<i>28</i>
4.2.5. <i>Učení vícevrstvé perceptronové sítě</i>	<i>29</i>
4.3. DEFINICE POJMŮ SENZITIVITA A SPECIFICITA	30
5. EXPERIMENTÁLNÍ ČÁST	32
5.1. SNÍMÁNÍ AVG SIGNÁLŮ - IMEXLAB 9000	32
5.1.1. <i>Pořízení záznamu AVG signálu</i>	<i>32</i>
5.1.2. <i>Program AVG IMEX</i>	<i>33</i>
5.2. DATA Z PROJEKTU GAČR.....	34
5.3. TRANSFORMOVANÁ DATA DO FORMÁTU PRO MATLAB	34
6. PŘEDZPRACOVÁNÍ DAT	35
6.1. ROZDĚLENÍ DAT A VYBRÁNÍ PŘÍZNAKŮ	35
6.2. KONTROLA NEÚPLNÝCH DAT A GRUBBSŮV TEST EXTRÉMních ODCHYLEK...	35
6.3. VYČLENĚNÍ DAT DO TRÉNOVACÍCH MNOŽIN	36
6.4. TEST NORMALITY ROZDĚLENÍ DAT	37
7. NAVRŽENÉ ZPŮSOBY KLASIFIKACE.....	39
7.1. KLASIFIKACE POMOCÍ VÍCEROZMĚRNÝCH STATISTICKÝCH METOD.....	39

7.1.1. Redukce dat pomocí metody hlavních komponent.....	39
7.1.2. Vlastní analýza testovacích dat pomocí shlukové analýzy.....	39
7.1.3. Klasifikace užitím vícerozměrných statistických metod - Program Clustering.....	40
7.2. KLASIFIKACE UŽITÍM NEURONOVÝCH SÍTÍ	41
7.2.1. Navržená topologie sítě.....	41
7.2.2. Forma vstupních dat pro síť	42
7.2.3. Učení neuronové sítě	42
7.2.4. Klasifikace pomocí neuronových sítí - Program NN	44
7.3. MODUL PACIENTSKÁ DATA	45
8. POROVNÁNÍ VÝSLEDKŮ KLASIFIKACE UŽITÝCH METOD	47
9. ZHODNOCENÍ DOSAŽENÝCH VÝSLEDKŮ	49
POUŽITÁ LITERATURA	50
SEZNAM OBRÁZKŮ	51
POUŽITÉ ZKRATKY A SYMBOLY	52
PŘÍLOHY	53
Příloha A - Struktura souboru AVG.DBF.....	53
Příloha B - Struktura souboru PAC.DBF	54
Příloha C - Klasifikace užitím shlukové analýzy (množiny AF, AP, ATP, LEG)	55
Příloha D - Klasifikace množiny AF užitím neuronových sítí (topologie T1-T4).....	57
Příloha E - Klasifikace množiny AP užitím neuronových sítí (topologie T1-T4).....	59
Příloha F - Klasifikace množiny ATP užitím neuronových sítí (topologie T1-T4).....	61
Příloha G - Klasifikace množiny LEG užitím neuronových sítí (topologie T5-T8)	63
Příloha H - Výsledky klasifikací jednotlivých množin použitých metod	65

1. Úvod do problematiky

Onemocnění srdečně – cévního systému zaujímají ve výčtu civilizačních chorob přední místo. Ateroskleróza (též arterioskleróza) je degenerativní onemocnění cévní stěny. Je to dlouhodobý proces, při němž dochází k tunutí cévní stěny a zužování jejího průsvitu. Kornatění tepen vzniká v důsledku ukládání tukových látek do stěny tepny, vznikají tzv. tukové proužky. Tyto změny jsou ještě plně vratné. Při dlouhodobě zvýšené hladině LDL cholesterolu dochází však již k nevratné přestavbě stěny. Cévy nejen tvrdnou, jejich stěna se ztlušťuje, vznikají na ní tuhé, tukové nánosy - tzv. aterosklerotické pláty. Pláty zužují průsvit a brání normálnímu průtoku krve. V důsledku sníženého průtoku krve v místě stenózy jsou tkáně a orgány (mozek, srdce, ledviny, dolní končetiny) nedostatečně zásobovány kyslíkem a živinami. Postupem času může dojít až k celkovému uzávěru cévy, úplnému zastavení přísunu živin do orgánů a jejich odumírání.

Hlavní příčinou vzniku aterosklerózy je především nadměrný příjem tukových látek. Rizikové faktory, které zvyšují pravděpodobnost jejího vzniku, jsou: kouření, hypertenze, diabetes mellitus, nedostatek pohybu, jistou roli hraje i genetika.

Projevy aterosklerózy jsou velmi rozmanité a závisí na oblasti, ve které se postižená céva vyskytuje. Nejznámější je postižení mozkových tepen způsobující mozkovou mrtvici a koronárních tepen způsobující anginu pectoris a v neposlední řadě srdeční infarkt. Ischemická choroba dolních končetin (ICHDK) je nejčastějším onemocněním periferních tepen a také jednou z nejčastějších a nejzávažnějších projevů aterosklerózy.

Diagnostika rozvinutých forem ICHDK je vcelku zvládnuta jak invazivními, tak neinvazivními postupy. Diagnostikovat její časnou formu, což je důležité zvláště u rizikových skupin populace, je však velmi obtížné. K upřesnění diagnostických závěrů slouží různá laboratorní vyšetření, ze zobrazovacích metod sem patří ultrazvuk. Nejpreciznější je rentgenové zobrazení s naplněním cévy kontrastní látkou, jedná se o tzv. digitální subtrakční angiografii (DSA). To je důležité zejména před případným operačním řešením nemoci.

Tato diplomová práce je orientována na neinvazivní metody diagnostiky ICHDK. Jedná se o vyhodnocování signálů, jež nesou informace o stavu a funkci srdečně-cévního systému. Takovými signály jsou především záznamy AVG (arteriovelocitogram). Tyto nesou v první řadě informaci o rychlosti průtoku krve v tepnách a jsou pořizovány ultrazvukovými dopplerovskými metodami doplněnými o měření systolických tlaků v jednotlivých lokacích tepenného řečiště a záznamem EKG.

V práci jsou stručně popsány neinvazivní diagnostické metody využívané převážně v diagnostice cév dolních končetin a metody jejich analýzy. Vlastní část práce tvoří návrh a realizace algoritmů zabývajících se klasifikací AVG signálů. Jako vhodné metody jsou využity vícerozměrná statistická analýza a postupy založené na aplikaci neuronových sítí.

2. Metodika snímání AVG signálů

2.1. Reologické vlastnosti krve a snímaný AVG signál

Ve všech studiích zabývajících se prouděním krve v úsecích srdečně cévního systému za podmínek makro i mikrocirkulace (včetně zařízení pro mimotělní oběhy) se vychází z předpokladu, že krev se chová jako spojitě prostředí. Meze platnosti tohoto předpokladu se ověřují. Sám fakt, že rozměry krvinek jsou velmi malé vzhledem k nejmenším rozměrům řečiště, není ještě postačujícím kritériem aplikovatelnosti nejrozumnějších teoretických přístupů a modelů. Práce z tohoto oboru dokazují, že při normálních fyziologických hodnotách hematokritu nelze zjistit oblasti čisté plazmy bez krevních částic ani u stěn velmi tenkých kapilár, [10].

Současné době je hemodynamika srdečně cévního systému studována jak v oblasti pulsačního proudění krve v cévách větších a velkých průměrů (oblasti makrocirkulací), tak proudění v cévách s průměry srovnatelnými s rozměry částic krevní suspenze (oblast mikrocirkulace). Hodnotí se vazoelastické a tixotropní vlastnosti krevní suspenze při nízkých smykových rychlostech, [10].

Režimy pulsačního proudění v cévním systému jsou mimo jiné charakterizovány i velikostí Reynoldsova čísla:

$$R_e = \frac{\bar{v} \cdot D}{\nu}, \quad (1)$$

kde \bar{v} je charakteristická rychlost v systole,
 D je průměr cévy,
 ν je kinetická viskozita krve (vnitřní tření).

Velikostí Reynoldsova čísla se odhaduje rozhraní mezi laminárním a turbulentním charakterem toku. Pro stacionární proudění je kritická hodnota $Re = 2320$, [10].

Všechny snímané a hodnocené biosignály, ať už ve formě elektrické, mechanické, chemické či tepelné, jsou projevem složitých funkčních i autoregulačních procesů organismu a nesou informace o jeho stavu a funkci. Snímání všech biosignálů je provázáno značnou variabilitou, která je podmíněna nejen podstatou metod a vlastních měření, ale i časovými změnami fyziologických parametrů měřených objektů - pacientů. Značný vliv na měřené signály má také okamžitý fyzický a psychický stav testovaného organismu.

Signálem AVG (arteriovelocitogramem) je označován signál, jež zobrazuje časovou změnu měřené rychlosti toku krve v průřezu krevního řečiště (nebo dopplerovského frekvenčního zdvihu). Tyto signály jsou získávány ultrazvukovými měřiči rychlosti toku krve a nesou informaci o střední rychlosti toku krve v místě přiložení ultrazvukové sondy. AVG signál je především závislý na:

- zvolené pracovní frekvenci systému,
- úhlu náklonu osy sondy vůči ose cévy (směru toku krve),
- rychlostním profilu proudění krve v řečišti.

2.2. Princip Dopplerova jevu, princip snímání signálů

Ultrazvukové dopplerovské systémy mohou být realizovány jako zařízení s modulovanou nebo nemodulovanou nosnou vlnou. Zařízení s nemodulovanou nosnou vlnou mohou pracovat jako směrová, nesměrová nebo obousměrná podle toho, jakým způsobem jsou detekována postranní pásma ve spektru přijímaného signálu. Zařízení s modulovanou nosnou vlnou pracují v současné době výhradně jako směrové impulsové systémy, [6].

Tato práce se zabývá zpracováním signálů získaných směrovým měřičem rychlosti toku krve s nemodulovanou nosnou vlnou.

Dopplerův jev

Využití Dopplerova jevu pro měření rychlosti či průtoku krve cévami je možné díky existenci odražečů v proudícím médiu. Těmito odražeči v krevním toku jsou erytrocyty. Princip je patrný z obr. 1. Pokud je vyslaná vysílacím ultrazvukovým měničem do tkáně ultrazvuková vlna tak, že měnič svírá s osou cévy úhel α , potom se pod úhlem β tato vlna odráží a dopadá na přijímací měnič. Frekvence vysílané ultrazvukové vlny je označena f_v , přijímané f_p .

Odrážení ultrazvukové vlny v krevním řečišti způsobují erytrocyty v tekoucí krvi, které rychlostí v proudí cévami. Frekvence přijímaného signálu se od frekvence vysílaného signálu liší o Dopplerův zdvih, který je dán rychlostí protékající krve, průměrnou rychlostí šíření ultrazvukové vlny ve tkáni c a úhly α a β . Konstrukčně bývá dopplerovská sonda provedena tak, že úhly α a β se liší jen nepatrně nebo jsou totožné. V praxi je rychlost krevních částic ($180\text{--}300\text{ cm}\cdot\text{s}^{-1}$) mnohem menší než rychlost šíření ultrazvuku ve tkáních ($1500\text{ m}\cdot\text{s}^{-1}$) a v krvi ($1570\text{ m}\cdot\text{s}^{-1}$). Za těchto předpokladů lze pro toto měření odvodit vztah pro Dopplerův frekvenční zdvih ve tvaru [6]:

$$f_d = 2 \cdot f_v \cdot \frac{v}{c} \cdot \cos(\alpha), \quad (2)$$


kde f_v je frekvence vysílané sondy,
 v rychlost měřené protékající krve,
 c průměrná rychlost šíření ultrazvuku ve tkáních
 α úhel mezi osou sondy a osou cévy.

Pracovní frekvence dopplerovských systémů užívaných v angiologii jsou v rozmezí $4\text{--}10\text{ MHz}$, rychlosti proudění krve v cévách jedinců jsou do $3\text{ m}\cdot\text{s}^{-1}$ a průměrná rychlost šíření ultrazvuku ve tkáních je $1500\text{ m}\cdot\text{s}^{-1}$. Dopplerovský signál je proto v rozsahu akustických frekvencí $200\text{ Hz} \div 15\text{ kHz}$.

Při vyšších pracovních frekvencích získáváme i vyšší dopplerovský frekvenční zdvih nesoucí informace o rychlosti krevního toku. Se stoupající pracovní frekvencí však vzrůstá i útlum a absorpce ultrazvuku ve tkáních. Pro nižší pracovní frekvence se sníží útlum ultrazvuku, ale sníží se i hodnota frekvenčního zdvihu. Vyšší pracovní frekvenci tedy dosahujeme menší hloubku vniku.

Směrnost vyzařovaných diagramů obou měničů dopplerovské sondy můžeme ovlivnit poměrem D/λ - tedy velikostí měničů a použitou pracovní frekvencí (v případě

možnosti volby). V angiologii se využívají sondy s průměrem do 10 mm a proto volba pracovní frekvence je závislá jednak na potřebné hloubce sledování a také na požadované rozlišovací schopnosti - šíři vyzařovaného svazku ultrazvukové sondy, [6].



Obr. 1 – Princip Dopplerova jevu

Dopplerovský frekvenční zdvih (1) je kromě jiného závislý na úhlu náklonu sondy α obou měničů vůči směru toku krve. Pro relativní měření rychlosti toku krve na většině periferních cév se statistickým vyhodnocením signálu dospělo k úhlu $\alpha = 35^\circ$, při kterém dosahujeme optimální velikosti snímaného signálu. Pro tento úhel je cejchována většina vyráběných přístrojů, [6].

Odrážející krevní částice - erytrocyty procházející průřezem uvažované cévy nemají stejné rychlosti. Rozdělení jejich rychlostí je vlivem pulsačního charakteru proudění i u řečiště bez patologických změn nestacionární. Patologické změny řečiště jako obliterace a kolaterální oběhy podstatným způsobem ovlivňují jeho rychlostní profil, [8].

Ve fyziologických případech má rychlostní profil téměř ve všech periferních cévách (až na počátek aorty) charakter laminárního proudění. Vektory rychlostí vytváří parabolický rychlostní profil. Při velkých rychlostech proudění, vyskytujících se nefyziologických případech po námaze nebo u patologických stavů se stenózami, přechází laminární charakter proudění v turbulentní. Kritická rychlost proudění, při které dochází k této změně, je určena dříve uvedeným Reynoldsovým číslem (1).

2.3. Diagnostický systém IMEXLAB 9000

Diagnostický systém IMEXLAB 9000 firmy IMEX (USA, v dnešní době firma Nicolet Vascular) slouží ke kompletní škále fyziologických vyšetření cév. Umožňuje provádět řadu neinvazivních vyšetření, jako jsou fotopletysmografická a pneumopletysmografická vyšetření, měření systolických tlaků krve sadou tlakových manžet a v neposlední řadě snímání a záznam AVG signálů pomocí obousměrného dopplerovského vyšetření využívajícího citlivé sondy s pracovní frekvencí 5 a 8 MHz.

Jak u dopplerovských vyšetření tak i u pletysmografických lze modifikovat velké množství parametrů, abychom dosáhli přesné interpretace naměřených průběhů a dat. Například lze nastavovat dopplerovské filtry, rychlost záznamu měřených průběhů,

směr měření toku krve, rozměry manžet, atd.

Pro snazší diagnostiku jsou zde implementovány přednastavené automatické testy, pomocí kterých lze krok po kroku provádět jednotlivé fáze vyšetření. Je zde i možnost vytvářet nová makra automatických testů s výstupním formátem zvoleným uživatelem. Kromě přednastavených testovacích procedur lze samozřejmě provádět i jednotlivá dílčí vyšetření podle potřeb. Získané výsledky měření je možno sestavovat do zpráv o vyšetření, jejichž forma může být také modifikována podle individuálních potřeb vyšetřujícího. Tyto vytvořené protokoly se buď uloží do paměti IMEXLAB 9000 pro pozdější vyvolání nebo přímo vytisknou pomocí integrovaného rozhraní pro tiskárnu.

Systém IMEXLAB 9000 je vybaven vnitřním počítačem standardu Macintosh, který zde plní funkci řídicí jednotky. Díky tomuto principu lze celý systém konfigurovat přidáváním potřebných modulů pro další vyšetření a aktualizací softwaru, který je umístěn na datové kartě. Snímané průběhy se dají uložit na datové medium v podobě disketové mechaniky 1,44". V dnešní době kompatibility datového systému souborů mezi formáty Macintosh a IBM není problém takto archivované soubory dekódovat na počítačích standardu IBM. Lze tedy vytvářet příslušné databáze vyšetřovaných pacientů.

2.4. Databáze AVG

Při aplikaci jakýchkoli klasifikačních postupů a algoritmů je nutné mít k dispozici přiměřeně rozsáhlou a ověřenou databázi biosignálů. Při použití analytických metod, využívajících metody učení (s učitelem, bez učitele), musejí být navíc vyznačeny specifické soubory signálů obsahující roztríděné trénovací vzory (množiny). Což u klasifikace AVG signálů nese nutnost konzultace s klinikem a ve shodě s anamnestickými a naměřenými daty určení těchto souborů dat.

Pro účely klasifikace AVG signálů by měla databáze obsahovat minimálně okolo 100 vyšetřených pacientů, zahrnující zdravé osoby i pacienty se stenózami a tepennými uzávěry. Ze statistického hlediska se nadále u každého měření vypočítávají průměrné hodnoty z několika po sobě jdoucích průběhů, odchylky a variační koeficienty, aby došlo k eliminaci ojedinělých artefaktů.

Pro standardizaci podmínek vyšetření (a stav pacienta při něm) je vhodné provádět měření signálů vždy na stejném přístrojovém vybavení, ve stejnou denní dobu (nejlépe v ranních hodinách, aby se vyloučila předešlá námaha organismu). Měření probíhá na testovaných osobách vleže po 10 ÷ 15 minutovém zklidnění. Po této době by mělo dojít k celkové normalizaci krevních tlaků v periferním krevním řečišti.


Nadále musí být provedeno rozměření snímaných signálů a je nutno určit u každého záznamu jednotlivé, předem stanovené znaky. Pro stanovení určujících parametrů musí být dopplerovské vyšetření doplněno také o snímání příslušného signálu EKG a snímání tlaku. Součástí každého vyšetření, a ne jinak je tomu i u snímání AVG signálů, je karta obsahující datum a čas měření, patientská data, jména vyšetřujícího klinika a nezbytné další údaje anamnézy pacienta.

3. Analýza AVG signálů

3.1. Parametry AVG signálu - definice

Obr. 2 ukazuje typické parametry odečítané z křivek AVG signálu, jimiž jsou [8]:

- relativní špičková dopředná v_s , (systolická) a zpětná (diastolická) rychlost v_d ,
- průměrná, střední hodnota rychlosti toku krve během srdečního cyklu v_m ,
- pulsační rychlost v_p jako rozdíl mezi špičkovou systolickou a stálou složkou rychlosti převažujícího směru proudem,
- zrychlení **A** a zpomalení **D** systolické vlny,
- čas vzestupu (doba zrychlení) t_A systolické vlny,
- doba mezi vrcholem systolické vlny a nasazením vlny refluxové t_{S-R} ,
- čas mezi vlnou R signálu EKG a nasazením systolické vlny (patou AVG) t_0 , doba běhu pulsové vlny mezi dvěma etážemi tepenného úseku t_B .



Obr. 2 – Rozměření signálu AVG

Výpočtem jsou dále stanovovány hodnoty:

- pulsační index

$$PI = \frac{v_s - v_d}{v_m} = \frac{v_{ss}}{v_m}, \quad (3)$$

- útlumový faktor


$$DF = \frac{PI_{prox}}{PI_{dist}}, \quad (4)$$

- koeficient úměrný perifernímu odporu řečiště

$$RP = \frac{v_d}{v_s}, \quad (5)$$

- ze změřených hodnot systolického tlaku krve na periférii a na arteria brachialis je určován tlakový index

$$BPI = \frac{TK_{S_perif}}{TK_{S_a.brach}}. \quad (6)$$



Obr. 3 – Průměrné hodnoty PI a TT zdravých mladých probandů

Kromě těchto uvedených parametrů je možné stanovovat i další odvozené jako jsou, [6]:

- Pourcelotův pulsační index PPI,
- index doby náběhu RTR z doby náběhu tA systolické vlny,
- index výška-šířka HWI z doby systolické vlny signálu,
- index délky dráhy PLI odvozený ze střední frekvence AVG signálu a srdeční periody.

Jedná se o teoreticky navržené parametry, které však nedoznaly praktického využití.

Klinicky nejvyššího významu dosáhly dva parametry: pulsační index **PI** a doba běhu pulsové vlny **t_B** (někdy také TT - transittime), jejichž hodnoty ve významných etážích tepenného řečiště pro zdravé probandy jsou uvedeny na Obr. 3, [8].

3.2. Přehled a shrnutí metod analýzy

V reálných případech klinických aplikací dopplerovských systémů je AVG signál vyjádřen spektrem frekvencí, k čemuž přispívá, [6]:

- tvar ultrazvukového svazku a jeho vztah ke geometrii cév krevního řečiště,
- tvar a velikost ultrazvukových měničů, pracovní frekvence,
- doba průchodu erytrocytů ultrazvukovým svazkem,
- odraz ultrazvuku na erytrocytech a dalších krevních částicích,

- spektrum vysílaného ultrazvukového signálu,
- přenosová charakteristika obvodů přijímače, typ a vlastnosti demodulátoru,
- současný výskyt tepenného a žilního toku v oblasti sondy,
- pohyb cévní stěny (v systolické fázi),
- ultrazvukové vlastnosti krve a cév.

3.2.1. Hodnocení tvaru signálu

Popis a hodnocení morfologie AVG signálu patří již ke standardní metodice při posuzování stavu a závažnosti cévních změn. Zásadní klinický význam má hodnocení signálů získaných směrovými dopplerovskými systémy. Typické průběhy AVG signálů v proximální a distální části ve vztahu k EKG signálu jsou uvedeny na Obr. 2. Jedná se o odečítání a hodnocení parametrů tak, jak byly definovány v kap. 3.1.

3.2.2. Hodnocení spektra dopplerovského signálu

Spektrum dopplerovského signálu lze zpracovávat jak ve frekvenční, tak v časové oblasti. Ve frekvenční oblasti se jedná o spektrální analýzu realizovanou některým z algoritmů DFT - diskrétní Fourierovy transformace. Relativní změny ve spektru dopplerovských signálů mohou být kvantifikovány výpočtem, [6]:

Kasamova spektrálního indexu širokopásmovosti

$$SBI = \frac{f_{\max} - f_x}{f_x} = 1 - \frac{f_s}{f_{\max}}, \quad (7)$$

kde f_{\max} okamžitá hodnota max. frekvence signálu,
 f_s okamžitá hodnota střední frekvence signálu v systolické vlně.

V časové oblasti je možné dopplerovský signál analyzovat:

- formou spektrogramu, kdy je aplikován některý z algoritmů FFT - rychlé Fourierovy transformace, např. násobením zkoumaného signálu časovým oknem $w(n)$ se středem v čase n :

$$X_n(k) = \sum_{m=0}^{N-1} x\left(m + n - \frac{N}{2}\right) w\left(m - \frac{N}{2}\right) e^{-j\frac{2\pi k}{N}m}, \quad (8)$$

kde k je frekvence,
 N je šířka okna.

Spektrogram dopplerovského signálu $x(n)$ je dán:

$$SPECTR_x(n, k) = |X_n(k)|^2, \quad (9)$$

- autoregresivním ARMA modelem:

$$AR_x(n, k) = \frac{\delta_p^n(n)}{\left| 1 + \sum_{m=1}^p a(m, n) e^{-j\frac{2\pi k}{N}m} \right|^2}, \quad (10)$$

kde p je řád modelu,
 $a(m, n)$ jsou komplexní časově proměnné koeficienty a
 $\delta_p^n(n)$ je přípustná chyba modelu.

- Besselovým rozdělením:

$$BD_x(n, k) = 2 \sum_{\tau=-\infty}^{+\infty} w_N(\tau) e^{-j \frac{2\pi k \tau}{N}} \left[\sum_{u=(-\tau-2\alpha|\tau|)/2}^{(-\tau+2\alpha|\tau|)/2} \frac{2}{\pi \alpha |\tau|} \sqrt{1 - \left(\frac{2\mu + \tau}{2\alpha\tau} \right)^2} x(n + \mu + \tau) x^*(n + \mu) \right] \quad (11)$$

3.2.3. Identifikační analýza

Hemodynamiku periferního krevního oběhu můžeme hodnotit také pomocí tzv. identifikační analýzy, při které stanovujeme přenosovou charakteristiku úseku cévního systému. Hodnocený tepenný úsek je díky teorii systémů považován za lineární přenosový člen se známými signály na vstupu i výstupu. Těmi jsou současně měřené AVG signály na proximální a distální části končetiny. Přenosová funkce a impulsní odezva takto definované části cévního systému se potom stanoví Fourierovou transformací odpovídajících komplexních spekter AVG signálu nebo korelační technikou, [6].

Aplikací FFT na digitalizovaný signál AVG stanovíme jeho frekvenční spektrum. Převodem do Laplaceovy transformace můžeme vyjádřit přenosovou funkci. Pro snazší určení polohy pólů v komplexní rovině zapisujeme přenosovou funkci ve tvaru racionální lomené funkce. Pro tepenný úsek dolní končetiny byla navržena metoda aproximace přenosové funkce pomocí modelu se dvěma komplexními a jedním reálným pólem přenosové funkce ve tvaru, [6]

$$H(p) = \frac{k}{(p^2 + 2\delta\omega p + \omega^2)(p + \gamma)}, \quad (12)$$

kde ω odpovídá elasticitě cév,
 γ perifernímu odporu řečiště a
 δ konstantě tlumení.

Z rozložení kořenů přenosové funkce lze hodnotit elasticnost tepen, vasokonstrikci i vasodilataci. Rozšíření v klinické praxi však tento postup nedoznal.

3.2.4. Vícerozměrné statistické metody

Množství i charakter AVG signálů snímaných zvláště z dolních končetin vytváří soubory dat vhodné pro statistické zpracování. Na data získaná standardní metodikou a definovaným způsobem předzpracovaná se mohou aplikovat některé metody vícerozměrné analýzy. Jejich podstatnou výhodou je možnost třídění - klasifikace signálů odpovídajících objektů, [7].

Vhodnými metodami klasifikace AVG signálů jsou metody shlukové analýzy, diskriminační analýza a analýza hlavních komponent. Uvedené metody mohou být aplikovány podle zvolené koncepce na celé soubory dat, jejich výběry nebo na data redukována. Základním předpokladem úspěšné interpretace získaných výsledků však je volba velikosti zpracovávaného souboru dat (rozsah souboru), jeho statistická významnost a struktura (zastoupení) jednotlivých typů hodnocených AVG signálů.

3.2.5. Klasifikace expertními systémy a neuronovými sítěmi

Ke klasifikaci rozsáhlých souborů dat, včetně dat snímaných biologických objektů, se s výhodou využívají expertní systémy. Jedná se o formu adaptivních učících se klasifikátorů aplikovaných na vhodné programové prostředí. Expertní systém se skládá z báze znalostí, báze dat a tzv. inferenčního mechanismu - programu, který s těmito bázemi definovaným způsobem pracuje. Základními problémy všech expertních systémů jsou kódování expertních znalostí reprezentovaných pravidly, míra spolehlivosti využívaných informací a nutnost neustálé adaptace znalosti, [6].

Kvalitativní posun v procesech klasifikace expertními systémy nastal aplikací neuronových sítí. Jejich základní vlastností je učení (bez učitele). Ke klasifikaci není třeba definovat algoritmus práce s daty. Proces učení, adaptace, využívá tzv. trénovací množinu, která neuronové síti předkládá vzory charakterizující daný problém. Do trénovací množiny je třeba vybrat reprezentativní vzory pro každou klasifikační třídu. Neuronová síť je definována svou topologií, tzn. počtem vstupních a výstupních neuronů, počtem skrytých vrstev a počtem neuronů v nich. Zásadní význam při aplikaci má i užití programové prostředí a struktura databáze signálů, [6].

4. Zvolené metody řešení

4.1. Využití vícerozměrných statistických metod

Nejčastěji užívané algoritmy vícerozměrných statistických metod vycházejí z předpokladu vícerozměrného rozdělení uvažovaného souboru dat. Při aplikacích v biologii, medicíně i technice můžeme považovat tento předpoklad za splněný - jedná se o měřitelné vlastnosti objektů, [7].

4.1.1. Ověření normality - test šikmosti a špičatosti

K ověření normality rozdělení slouží řada testů. Interpretovat jejich výsledky je však třeba uvážlivě. Efektivní algoritmy těchto testů odhalí i nepatrné odchylky od normality, které však většinou nebrání následnému provedení analýzy. Je proto možné test normality využít jen orientačně. V praxi se běžně testují jen [4]:

- marginální rozdělení,
- rozdělení vybraných lineárních kombinací proměnných,
- jednorozměrné a vícerozměrné charakteristiky šikmosti a špičatosti.

Test šikmosti a špičatosti jednorozměrného rozdělení

Test vychází z výpočtu charakteristiky šikmosti rozdělení pro jednotlivé proměnné z výběru [4]:

$$\sqrt{b_1} = \frac{\sqrt{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left[\sum_{i=1}^n (x_i - \bar{x})^2 \right]^{3/2}} \quad (13)$$

a charakteristiky špičatosti rozdělení:

$$b_2 = \frac{n \sum_{i=1}^n (x_i - \bar{x})^4}{\left[\sum_{i=1}^n (x_i - \bar{x})^2 \right]^2}, \quad (14)$$

kde x_i je i -tá proměnná výběru,
 \bar{x} střední hodnota proměnné ve výběru,
 n počet proměnných ve výběru.

Střední hodnoty uvedených charakteristik jsou odpovídajícími protějšky charakteristik šikmosti $\sqrt{\beta_1}$ a špičatosti β_2 základního souboru, které pro případ normality nabývají hodnot:

$$\sqrt{\beta_1} = 0 \text{ a } \beta_2 = 3. \quad (15)$$

Pro ověření normální šikmosti se užívá kritéria [4]:

$$K_3 = \sqrt{\frac{b_1(n+1)(n+3)}{6(n-2)}} \quad (16)$$

a pro ověření normální špičatosti kritéria:

$$K_4 = \sqrt{\frac{(n+1)^2(n+3)(n+5)}{24n(n-2)(n-3)}} \cdot \left(b_2 - 3 + \frac{6}{n+1} \right). \quad (17)$$

Jedná se o dvoustranné testy, takže hypotéza $H(3): \beta_1 = 0$ nebo $H(4): \beta_2 = 3$ se zamítá na hladině významnosti α , jestliže testové kritérium v absolutní hodnotě překročí kvantit $z_{1-\alpha/2}$ normovaného normálního rozdělení.

Test šikmosti a špičatosti vícerozměrného rozdělení

Test využívá vícerozměrnou charakteristiku šikmosti [4]:

$$B_1 = \frac{1}{n^2} \sum_{i=1}^n \sum_{i'=1}^n \left[(x_i - \bar{x})' S^{-1} (x_{i'} - \bar{x}) \right]^3 \quad (18)$$

a vícerozměrnou charakteristiku špičatosti [4]:

$$B_2 = \frac{1}{n^2} \sum_{i=1}^n \left[(x_i - \bar{x})' S^{-1} (x_i - \bar{x}) \right]^3, \quad (19)$$

kde x_i je i -tý sloupcový vektor výběru,
 \bar{x} vektor výběrových průměrů (výběrových centroidů) p -rozměrného souboru s prvky

$$\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{ij}, \quad j = 1, 2, \dots, p, \quad (20)$$

kde n je počet objektů výběru,
 S výběrová kovarianční matice.

Odchylka od očekávané střední hodnoty $E(B_1) = 0$, příslušející vícerozměrnému normálnímu rozdělení se pokládá za významnou na hladině α , pokud hodnota testového kritéria

$$K_5 = \frac{n}{6} \cdot B_1 \quad (21)$$

překročí kvantil $\chi^2_{1-\alpha} [p(p+1)(p+2)/6]$.

Odchylka od očekávané hodnoty $E(B_2) = p(p+2)$ se pokládá za významnou na hladině α , pokud absolutní hodnota testového kritéria

$$K_6 = \sqrt{\frac{n}{8p(p+2)}} \cdot [B_2 - p(p+2)] \quad (22)$$

překročí kvantil $z_{1-\alpha/2}$ normovaného normálního rozdělení.

4.1.2. Grubbsův test extrémních odchylek

Při získávání biosignálů na klinickém pracovišti může někdy docházet ke vzniku artefaktů, které uniknou pozornosti obsluhujícího personálu. Vzhledem k tomu, že pořizování dat není nikdy zcela ošetřeno vůči těmto vlivům, je třeba provádět kontrolu všech naměřených dat a tyto vyloučit z dalšího procesu zpracování. Tato kontrola může být provedena vizuálním prohledáním souboru dat nebo pomocí statistických testů, které tyto odchylky odhalí. Jedním z těchto jednoduchých testů je právě Grubbsův test extrémních odchylek, [1].

Obecně testy extrémních odchylek předpokládají, že známe výběr ze základního souboru, který má přibližně normální rozdělení $N_O = (\mu, \sigma)$. Naměřené hodnoty se seřadí podle velikosti

$$x_1 \leq x_2 \leq \dots \leq x_{n-1} \leq x_n, \quad (23)$$

přičemž se předpokládá, že extrémní hodnota může být na pozici x_1 nebo x_n . Určí se tedy hodnoty testového kritéria

$$T_1 = \frac{\bar{x} - x_1}{\sigma^2} \text{ a } T_n = \frac{x_n - \bar{x}}{\sigma^2}, \quad (24)$$

kde \bar{x} je aritmetický průměr výběru a
 σ^2 je směrodatná odchylka výběru.

Kritické hodnoty jsou tabelovány a platí $T_1(P) = T_n(P)$. Hypotézu H_0 , že hodnota patří do daného výběru, zamítáme, pokud $T_1 > T_1(P)$, resp. $T_n > T_n(P)$. Hodnotu z výběru vyřadíme a opakujeme test. K testu lze provést kontrolu. Pokud byla hodnota z výběru vyřazena správně, došlo k výraznému poklesu hodnoty směrodatné odchylky.

4.1.3. Redukce počtu dat pomocí metody hlavních komponent

V mnoha případech je výchozí počet znaků charakterizujících daný signál příliš velký. Pro zjednodušení výpočtů a pro názornější grafické zobrazení je tedy vhodné přiměřeně upravit (zredukovat) vhodným výběrem či transformací počet znaků v datové matici. Podmínkou takových operací je zachování maximálního množství informací v novém systému znaků, jejich nekorelovanost, atd. Významnou metodou klasifikace a také redukce počtu dat v souborech je právě analýza hlavních komponent, [6].

Metoda spočívá v určení vlastních vektorů kovarianční matice vstupních dat (měřených AVG signálů) a ve stanovení váhových koeficientů - hlavních komponent, kterými se vlastní vektory uplatní v uvažovaném AVG signálu. Hlavní komponenty popisují variabilitu a závislost jednotlivých proměnných v daném souboru dat. Reprezentují vhodnou lineární transformaci původních dat (měřených AVG signálů) sestupně s nejvyšší variabilitou -největším rozptylem. Hlavní komponenty jsou navzájem nekorelované, [4].

Snímaný signály jsou považovány za vstupní vektory popsané vždy p parametry (vzorky) v celkovém počtu n měření:

$$x_i = x_{1i} + x_{2i} + \dots + x_{pi}, \quad (25)$$

kde $i = 1, 2, \dots, n$ jsou jednotlivé AVG signály.

Hlavní komponenty a_j jsou lineární kombinací váhových vektorů v a složek vstupních vektorů x

$$a_j = v_{1j}x_1 + v_{2j}x_2 + \dots + v_{pj}x_p, \quad (26)$$

kde $j = 1, 2, \dots, p$ je počet parametrů AVG signálu.

Hodnoty $v_{1j}, v_{2j}, \dots, v_{pj}$ jsou prvky vlastního vektoru kovarianční matice S odvozené z množiny všech p -rozměrných měření na n průbězích AVG signálu daného souboru. Přitom platí že:

$$v_{1j}^2 + v_{2j}^2 + \dots + v_{pj}^2 = 1 \quad (27)$$

Problém hlavních komponent je vlastně v numerickém řešení vlastních vektorů kovariančních matic S . Ta je maticí symetrickou s diagonálními prvky tvořenými rozptyly, nediagonálními prvky jsou vzájemné kovariance mezi proměnnými. Řešením charakteristické rovnice této matice se dospěje pro vlastní vektor

$$S \cdot v = \lambda \cdot v, \quad (28)$$

kde λ je vlastní číslo matice S .

Zpětná rekonstrukce průběhu AVG signálu je možná z vypočtených hlavních komponent a vlastních vektorů kovarianční matice:

$$x_i^* = a_1v_{1i} + a_2v_{2i} + a_3v_{3i} + \dots \quad (29)$$

4.1.4. Shluková analýza

Jednou z možností využití informace obsažené ve vícerozměrných pozorováních je roztřídění objektů do několika poměrně stejnorodých shluků. Uplatnění této metody analýzy vede k příznivým výsledkům zejména tam, kde se studovaný soubor reálně rozpadá do tříd, tj. objekty mají tendenci se seskupovat do přirozených shluků. Použitím vhodných algoritmů se pak podaří odhalit strukturu studované množiny objektů a jednotlivé objekty klasifikovat. Mimo jiné se tím dosáhne radikálního snížení dimenze úlohy tak, že řadu uvažovaných proměnných zastoupí jediná proměnná, vyjadřující příslušnost k takto definované třídě (vzoru, typu), [4].

Použití shlukové analýzy se zcela nevzdáváme ani za méně příznivých okolností, kdy objekty nejeví tendenci k vytvoření přirozených tříd, ale spíše připomínají víceméně homogenní chaos. Cíle analýzy zde musí být ovšem skromnější.

Cílem shlukové analýzy je v podstatě dosažení stavu, kdy jednotlivé objekty uvnitř shluků si jsou podobné co nejvíce a objekty z různých shluků co nejméně. Třidu nebo shluk objektů tedy chápeme jako množinu objektů se společnými nebo alespoň podobnými proměnnými, znaky. Blízkost či podobnost objektů posuzujeme na základě míry vzdálenosti objektů v m -rozměrném prostoru proměnných. Mírou vzdálenosti objektů pro kvantitativní proměnné jsou běžně základní metriky, [4]:

- Hammingova metrika, čili Manhatanská vzdálenost, je definována vztahem

$$d_E(x_k, x_l) = \sqrt{\sum_{j=1}^m (x_{kj} - x_{lj})^2}, \quad (30)$$

- Eukleidova metrika, čili geometrická vzdálenost, je standardním typem vzdálenosti, který je definován vztahem

$$d_H(x_k, x_l) = \sum_{j=1}^m |x_{kj} - x_{lj}|, \quad (31)$$

- zobecněná Minkowskiho metrika vztahem

$$d_M(x_k, x_l) = \sqrt[n]{\sum_{j=1}^m |x_{kj} - x_{lj}|^n}, \quad (32)$$

kde pro $n = 1$ jde o Hammingovu metriku a pro $n = 2$ o Eukleidovu. Čím je n větší, tím více je zdůrazňován rozdíl mezi vzdálenými objekty. Všechny tyto metriky neuvažují závislost mezi proměnnými. Zahrneme-li do vztahu pro vzdálenost i vazby mezi proměnnými, vyjádřené kovarianční maticí C , dostaneme statistickou míru, zvanou

- Mahalanobisova metrika

$$d_{MA}(x_k, x_l) = \sqrt{(x_k - x_l)^T C^{-1} (x_k - x_l)}. \quad (33)$$

Ta se společně s Eukleidovou metrikou nejvíce používá v praxi. Ve všech uvedených případech jsou si dva objekty tím bližší, čím je jejich vzdálenost menší.

4.2. Využití neuronových sítí

4.2.1. Úvod do problematiky neuronových sítí


Problematika umělých informačních systémů, které jsou principiálně schopny napodobovat funkce nervových soustav živých organismů podstatně dokonalejším způsobem, než to může činit dosavadní, tzv. konvenční výpočetní technika, přitahuje pozornost odborníků již mnoho let.

Mezi neuronovými sítěmi a konvenčními počítači existuje zásadní rozdíl ve způsobu práce. Konvenční počítačové a informační systémy pracují podle předem stanoveného postupu - algoritmu. Podle něj zpracovávají jednotlivé dílčí operace. Oproti tomu neuronové systémy uskutečňují velmi vysoký počet dílčích operací současně a pracují bez algoritmu. Jejich činnost je založena na procesu učení, při kterém se neuronová síť postupně co nejlépe adaptuje k řešení dané úlohy, [3].

Umělými neuronovými sítěmi je možno řešit složitější úlohy, jako je rozpoznávání písma, predikce na burzách, identifikace podpisů, klasifikace a interpretace dat, atd.

4.2.2. Biologický model neuronu


Umělé neuronové sítě byly vytvořeny na základě jednoduchých modelů neuronů-funkčních buněk nervového systému živých organismů. Tento rys předurčuje, že umělé neuronové sítě se mohou chovat stejným nebo alespoň podobným způsobem jako jejich biologické modely, Obr. 4. Většina současných aplikací umělých neuronových sítí využívá selektivní a generalizační vlastnosti těchto struktur. Některé novější struktury jsou navíc schopné řešit i úlohy složitějšího typu, jako jsou např. optimalizační úlohy.



Obr. 4 – Biologický model neuronu

4.2.3. Základní model umělého neuronu

Podstatou návrhu umělých neuronových sítí je tedy modelování jednak struktury (topologie) a jednak vlastní činnosti biologických neuronových sítí. Základním strukturálním, ale i funkčním stavebním elementem biologického informačního systému, je nervová buňka – neuron. Analogicky k tomu základním stavebním prvkem umělé neuronové sítě je neuron umělý, resp. jeho matematický model. Umělé neuronové sítě jsou pak tvořeny množinou modelů neuronů, určitým způsobem seskupených a mezi sebou vzájemně vhodně propojených.



Obr. 5 – Schéma analogie biologického a umělého neuronu

V modelu umělého neuronu dochází k náhradě biologických funkcí funkcemi matematickými. Existuje mnoho typů modelů umělých neuronů, avšak v praxi je dodnes nejpoužívanější tzv. formální model neuronu. Jedná se o základní typ neuronu, který je často podle svých autorů nazýván McCulloh-Pittsův neuron. Analogii mezi biologickým a umělým neuronem zachycuje Obr. 5, [3].

Vstupy x_1, x_2, \dots, x_n modelují dendrity, váhy spojení w_1, w_2, \dots, w_n modelují synapse, přičemž n je konečný počet vstupů, resp. počet neuronů v předchozí vrstvě. Agregace vstupních signálů, jejich porovnání s prahovou hodnotou Θ a následně jejich nelineární zobrazení představují model těla neuronu, tj. vyhodnocení celkového vstupního aktivačního potenciálu a jeho transformaci na výstupní signál. Každý neuron má jediný výstup y , který simuluje činnost axonu. Tento jediný výstup je samozřejmě možno rozmnožit do potřebného počtu kopií – vstupů do následných neuronů. V každém neuronu se vstupní hodnoty transformují na výstup pomocí minimálně dvou

výpočetních procedur. Konkrétně se jedná o výpočet vstupního potenciálu y_a a o tzv. aktivační funkci f .

Vstupy do neuronu – x_i

Vstupem neuronových sítí mohou být číselné i nečíselné (např. obrazce apod.) parametry. V převážné většině bývají však ve formě reálných čísel. V závislosti na konkrétní poloze neuronu v dané neuronové síti můžeme vstupy rozdělit do dvou skupin. První skupinu tvoří výstupy z jiných, předcházejících (presynaptických) neuronů, druhou skupinu vstupů představují podněty z vnějšího okolí. Tento vstupní vektor $X = [x_1, x_2, \dots, x_n]$ představuje soubor konkrétních hodnot, které mohou být vyjádřeny buď v kvalitativní, nebo kvantitativní formě. Kvalitativní formou se rozumí vyjádření vstupní veličiny obvykle booleovskými hodnotami ve smyslu log. 1 a log. 0 (ve smyslu ano nebo ne). Každý vstup je vázán k dané vlastnosti a konkrétní kvalitativní hodnoty vyjadřují, zdali tato vlastnost v systému existuje či nikoli. Oproti tomu kvantitativně je hodnota vstupní veličiny vyjádřena konkrétním reálným číslem. Toto číslo potom představuje skutečnou hodnotu měřené veličiny, [3].

Váhy spojení – w_i

V neuronových sítích jsou navzájem mezi sebou neurony propojeny a jejich vzájemné vazby popisují váhy spojení w_i . Tyto váhy ovlivňují jednotlivé vstupy do neuronů a tím i celou neuronovou síť. Hodnota každé váhy reprezentuje citlivost, s jakou konkrétní vstup působí na výstup z neuronu. Váhy spojení se obvykle vyjadřují reálnými čísly, jejichž hodnoty vypovídají o průchodnosti, případně o důležitosti daného spojení. Váhy patří do skupiny parametrů, jejichž změnou je možné v procesu učení dosáhnout shody mezi výstupy zkoumaného procesu a výstupy neuronové sítě. Právě výpočty aktuálních hodnot vah a jejich postupné ladění představují podstatnou část učících algoritmů neuronových sítí. Matematická závislost mezi jednotlivými vstupy x_i neuronu a příslušnými váhami w_i je proces, jež se obecně konfluencí a lze ho popsat následující zobecněnou rovnicí, [5]:

$$z_i(k) = x_i(k) \oplus w_i(k), \quad (34)$$

kde \oplus je obecný operátor konfluencí.

V případě zde popisovaného základního modelu neuronu se uvažuje lineární hodnota zmíněného operátora. Tzn., že je možné obecný operátor konfluencí nahradit prostým součinem hodnot x_i a w_i . Výše uvedený vztah (34) pak přechází na rovnici, [5]:

$$z_i(k) = x_i(k) \cdot w_i(k), \quad (35)$$

Práh neuronu – Θ

Prahem neuronu se rozumí hodnota, kterou musí vstupní signál překonat, aby se mohl dál šířit neuronovou sítí (analogie s biologickým neuronem). Hodnota prahu tedy definuje stav, kdy je neuron aktivován. Pokud je na vstupu neuronu hodnota nižší, než je prahová, je na jeho výstupu signál odpovídající jeho pasivnímu stavu. V okamžiku,

kdy dojde k překročení prahové hodnoty, stává se neuron aktivním a výstupní signál roste v závislosti na tvaru aktivační funkce.

Oproti biologickým neuronům je zde často práh využíván k tomu, aby posouval signál při vstupu do aktivační funkce. Práh obecně představuje bariéru na vstupu do neuronu z okolního světa, nikoliv z jiných neuronů. Následkem toho již výsledná přenášená hodnota není zmenšena o práh (jako v případě biologického neuronu), ale prahová hodnota se „aktivně“ podílí na výstupu z neuronu. Při této úvaze se práh neuronu modeluje jako násobek synaptické váhy w_0 a 1, resp. -1. Číslice 1 a -1, pak představují fiktivní vstup do neuronu x_0 s konstantní hodnotou rovné 1 nebo -1, podle toho, zda se signál šíří neuronovou sítí doprava nebo doleva. To záleží na konkrétní řešené úloze a přijatém paradigmatu (souhrnné parametry jako např. topologie, algoritmus učení, model neuronu atd.) neuronové sítě, [5].

Agregační funkce neuronu – y_a

Úkolem agregační funkce neuronu je určitým způsobem sloučit vstupní signály neuronu. To znamená transformovat $n+1$ – rozměrný vstupní vektor $x_i (i = 0, 1, \dots, n)$ na skalární signál y_a , který pokračuje na vstup aktivační funkce neuronu. Zavedeme-li zobecněný operátor agregace G , pak lze proces agregace popsat obecnou rovnicí, [3]:

$$y_a(k) = G \sum_{i=1}^n z_i(k), \quad (36)$$

resp. po dosazení z rovnice (33) za $z_i(k)$

$$y_a(k) = G \sum_{i=1}^n x_i(k) \cdot w_i(k). \quad (37)$$

V případě použití výše definovaného základního modelu neuronu můžeme operátor agregace G nahradit operací sumace. Po provedení této náhrady a zavedení prahu přechází vztah (35) na tvar

$$y_a(k) = \sum_{i=1}^n x_i(k) \cdot w_i(k) + \Theta. \quad (38)$$

Jak bylo uvedeno v kap. 0, lze práh formálně považovat za speciální případ váhy spoje vedoucího od fiktivního neuronu, jehož výstup má trvale hodnotu +1, resp. -1. Pak lze zavést substituci

$$\Theta = w_0 x_0. \quad (39)$$


Vstupní potenciál lze pak zapsat ve tvaru

$$y_a(k) = \sum_{i=0}^n x_i(k) \cdot w_i(k). \quad (40)$$

Aktivační funkce neuronu - $f(y_a)$

Úkolem aktivační funkce neuronu je převést hodnotu vstupního potenciálu na výstupní hodnotu z neuronu. Konkrétní tvary přenosových funkcí bývají velmi různorodé. V principu se dají tyto funkce rozdělit na lineární a nelineární, případně na

spojité a diskrétní. Výběr vhodné přenosové funkce je závislý na konkrétním typu řešené úlohy, případně na konkrétní poloze neuronu v neuronové síti. Např. se běžně používají jiné aktivační funkce pro neurony ve skrytých vrstvách a jiné aktivační funkce pro neurony ve vrstvě výstupní. Výběr vhodné přenosové funkce rovněž ovlivňuje náročnost technické popř. programové realizace navržené neuronové sítě. Z nejčastěji používaných aktivačních funkcí jmenujme např. aktivační funkci skokovou, po částech lineární, sigmoidální, hyperbolicko-tangenciální nebo gaussovskou atd. Funkční předpisy a průběhy vybraných aktivačních funkcí jsou uvedeny na Obr. 6, [3].



Obr. 6 – Průběhy vybraných aktivačních funkcí


4.2.4. Struktura neuronové sítě

Nejjednodušší neuronovou sítí je vlastně osamocený neuron, tzv. perceptron. Jeho aktivační funkci tvoří funkce signum (výstup neuronu je buď 1, nebo -1 v závislosti na jeho potenciálu). Perceptron je tedy schopen klasifikovat do jedné z tříd 1 a -1. Z předložených vzorů je tedy schopen se naučit jejich klasifikaci. Takováto neuronová síť má ovšem jedno velké omezení, a tím je nutná lineární separabilita množin, které chceme klasifikovat do tříd. Perceptron totiž hledá dělicí nadrovinu mezi předkládanými vektory, která tyto vektory rozdělí podle požadované klasifikace. K tomu se využívá tzv. delta pravidlo. Pokud takováto nadrovinu neexistuje (pokud se shluky vektorů prolínají), není perceptron schopen naučit se korektně klasifikovat všechny předložené vstupy. Mimo jiné z tohoto důvodu je často nezbytné využít vícevrstvé neuronové sítě, jež toto omezení značně minimalizují.

Vícevrstvá neuronová síť je složena z neuronů, které jsou podobné jednoduchému perceptronu. Tyto neurony jsou vzájemně propojeny, Obr. 7. Aby uspořádání sítě dávalo smysl, tj. aby síť plnila svoji funkci, musíme neurony propojit mezi sebou podle určitých pravidel. Neurony musí být uspořádány do vrstev. Z každého neuronu v dané

vrstvě vedou spoje do všech neuronů ve vrstvě následující. Spoje jsou tedy nataženy pouze mezi dvěma nejbližšími vrstvami, nikoli mezi různými vrstvami. Spoje navíc nejsou mezi neurony jedné vrstvy, jak tomu je např. u Hopfieldovy sítě, [9], [2].

První vrstva, do které přicházejí signály, se nazývá vstupní vrstva. Tato vrstva plní pouze funkci rozdělení signálu do jednotlivých neuronů v následující vrstvě. Nemá tedy žádnou logickou funkci. Slouží podobně nějakému spojení několika drátů. Často tuto vrstvu nepočítáme mezi neuronovou vrstvou. Další vrstvy vyjma poslední se nazývají skryté vrstvy. Z hlediska uživatele jsou nezajímavé. Poslední vrstva, ze které vedou jednotlivé výstupy, se nazývá výstupní. Jak skryté vrstvy, tak i výstupní vrstva jsou složeny ze stejných neuronů. Celá síť je tedy složena z jediného druhu neuronu. Pokud tedy řekneme, že síť má tři vrstvy, rozumíme, že má vstupní vrstvu, dvě skryté a jednu vrstvu výstupní, [7], [2].



Obr. 7 – Struktura vícevrstvé perceptronové sítě

Mezi výše uvedenými principy může být nalezeno několik důležitých vlastností. Za prvé, neuronové sítě jsou vytvořeny propojením neuronů a za druhé, chování neuronových sítí je dáno předáváním informací mezi jednotlivými neurony prostřednictvím synapsí (propojení). Dá se říci, že máme k dispozici 3 parametry, které lze měnit: synaptické váhy mezi neurony, strmost přenosových (aktivačních) funkcí včetně jejich tvaru a prahové hodnoty neuronů, Obr. 7.

4.2.5. Učení vícevrstvé perceptronové sítě

Učení je základní a podstatná vlastnost neuronových sítí. V neuronové síti při něm dochází ke změnám, síť se tak adaptuje na řešení daného problému. Učení se v umělé neuronové síti realizuje nastavováním vah mezi neurony. V praxi se vahám přisoudí počáteční hodnoty, které mohou být buďto náhodně zvolené, nebo vybrané podle nějakého podobného případu. Pak se do sítě přivede trénovací vstup. Síť poskytne výstup, odezvu. Existují dva typy učení: s učitelem a bez učitele, [9].

Vícevrstvá perceptronová síť je schopna řešit problémy daleko komplexněji než její jediný neuron. Musíme tedy uvážit, že síť je daleko složitější, a navíc zde došlo ke změně aktivační funkce neuronů z jednoduché Heavisideovy funkce na funkci komplexnější (např. na Obr. 6 sigmoidální funkce, hyperbolicko tangenciální funkce, atd.). Právě použití složitější aktivační funkce je klíčovým prvkem, protože nám dovoluje přenášet dostatek informace o vstupech resp. výstupech po jednotlivých vahách přes jednotlivé vrstvy sítě. Tomu musí být přizpůsobeno i pravidlo pro učení

takové sítě.

Jedním z nejužívanějších pravidel pro učení vícevrstvé perceptronové sítě je algoritmus zpětného šíření chyby back-propagation. Jedná se o typ učení sítě s učitelem. Princip tohoto pravidla spočívá v tom, že chyba, zjištěná při dopředném šíření signálu, se postupně šíří zpět od výstupu ke vstupům a jednotlivé váhy spojení jsou modifikovány v poměru dané chyby. Učení je samozřejmě opakovaný děj, tj. vzor je nutné předkládat opakovaně, dokud si ho síť nezapamatuje, [9].

Celý algoritmus back-propagation lze shrnout do několika kroků:

1. Všechny váhy v síti jsou nastaveny na náhodné hodnoty.
2. Síti je na vstup předložen vzor z trénovací množiny a jsou vypočítány výstupy jednotlivých neuronů.
3. Dále je určena energie sítě a chyba pro výstupní vrstvu.
4. Dochází ke zpětnému šíření chyby o jednu vrstvu blíž vstupům. Poté se modifikují váhy a prahy výpočtem jejich přírůstků. Tento krok je opakován pro všechny vrstvy sítě, směrem od výstupní vrstvy ke vstupní.
5. Pokud byly síti předloženy všechny vzory z trénovací množiny, pokračuje se krokem 6, jinak se postup opakuje od bodu 2.
6. Je-li energie sítě za poslední iteraci menší než námi zvolená hodnota, pak je učení sítě ukončeno s konstatováním, že síť byla naučena s požadovanou přesností. V opačném případě je postup opakován od bodu 2.

Nevýhodou algoritmu back-propagation je jeho velká citlivost na počáteční nastavení vah a skutečnost, že není zajištěna jeho konvergence do globálního minima (i když to je možné částečně potlačit vhodnou volbou koeficientů setrvačnosti a rychlostí učení). Přesto je v praxi při učení dopředných vícevrstvých neuronových sítí hojně využíván.

4.3. Definice pojmů senzitivita a specifita

Hodnotícími parametry diagnostických metod jsou senzitivita a specifita. Určují se na základě vzniku čtyř možných situací, závěrů, které mohou při vyšetření nastat. Těmi jsou:

- falešně pozitivní diagnóza (FP) – osoba nemá danou chorobu, ale tato je nesprávně diagnostikována;
- správně pozitivní diagnóza (TP) – choroba je správně diagnostikována;
- falešně negativní diagnóza (FN) – osoba má danou chorobu, ale tato není diagnostikována;
- správně negativní diagnóza (TN) – osoba nemá danou chorobu, která není správně diagnostikována.

Oba tyto parametry jsou určovány oproti referenční metodě, podle které lze s určitostí diagnostikovat nebo naopak vyloučit přítomnost choroby.

Parametr senzitivita je pak definován jako procento nemocných majících danou chorobu a současně majících patologický test (pravděpodobnost, s jakou daný test

stanoví správnou diagnózu). Určí se podle vztahu:

$$\textit{senzitivita} = \frac{TP}{TP + FN} . \quad (41)$$

Parametrem specificity je určeno procento osob, kteří mají normální test a současně nemají patologický nález (pravděpodobnost, s jakou daný test správně vyloučí testovanou chorobu), [9]. Specificita je definována dle vztahu

$$\textit{specificita} = \frac{TN}{TN + FP} . \quad (42)$$

Obě tyto hodnoty spolu souvisí, zpravidla platí, že při růstu senzitivity dojde k poklesu specificity, a naopak. Pro screening jsou zpravidla preferovány testy s vysokou senzitivitou a malou specifitou – dává se přednost vyššímu procentu falešně pozitivních testů, které jsou později odhaleny dalším vyšetřením. Na testy pro intervenční léčbu jsou obvykle kladeny požadavky na vysokou specificitu – aby nebyl zdravý jedinec zbytečně podroben organismus zatěžující léčbě.


5. Experimentální část

5.1. Snímání AVG signálů - IMEXLAB 9000

5.1.1. Pořízení záznamu AVG signálu

Pro získání poznatků o průběhu vyšetření a o vzniku signálů AVG bylo pomocí diagnostického systému IMEXLAB 9000 provedena série dopplerovských měření AVG signálů. K měření byly použity dvě dostupné dopplerovské sondy, jedna pracující s frekvencí 5 MHz a druhá s frekvencí 8 MHz. Signály byly experimentálně snímány z různých míst tepenného řečiště testovaných subjektů. Měření probíhalo v laboratorních podmínkách ve školní laboratoři.

Systém IMEXLAB 9000 zaznamenává průběh signálu dle volby uživatele buď pomocí připojené tiskárny na papír, nebo do souboru na záznamové médium. Tento soubor nese název *.DOP (jméno souboru definuje uživatel při ukládání). Takto uložený soubor obsahuje zaznamenaný průběh měřeného signálu doplněný o informace příslušející vyšetření. Těmito mohou být např. jméno a příjmení pacienta, datum narození, věk, váha, datum vyšetření, vyšetřující pracovník, atd.



Obr. 8 – Průběhy AVG signálů pořízených systémem IMEXLAB 9000


Uložené soubory byly využity při zpracování v prostředí Matlab. Struktura souborů má takovou formu, že obsahuje jednak textovou část (od začátku souboru), tak část kódující hodnoty vlastního signálu, bylo nutno tyto dvě části v první řadě detekovat a od sebe odlišit.

Systém IMEXLAB 9000 umožňuje zaznamenat signály pouze pro tři různé

rychlosti posunu časové osy, a to 10 mm.s^{-1} , 25 mm.s^{-1} a 50 mm.s^{-1} , což odpovídá celkovým délkám časové osy 10 s, 4 s a 2 s. V textové části souboru je mimo jiné uveden i určující údaj o měřítku osy y, jež může být ve formátu kHz nebo cm.s^{-1} . Tyto rozsahy jsou navzájem kompatibilní a převod je realizován podle vztahu (2). Díky těmto poznatkům bylo bez větších problémů možné zobrazit zaznamenaný signál v celé jeho délce a rozsahu tak, jak ho zobrazuje na obrazovce systém IMEXLAB 9000, nezávisle na formátu uloženého souboru, což dokumentuje Obr. 8.

5.1.2. Program AVG IMEX

Tento program slouží pro přehledné zobrazení AVG signálů pořízených systémem IMEXLAB 9000. Je sestaven v prostředí GUI vývojového prostředí Matlab. Jeho podoba je vyobrazena na Obr. 9. Pomocí tohoto programu lze nejen zobrazit uložené AVG signály, ale i doplňující údaje vyšetření. Využitím jednoduchých pomůcek lze načtený signál zobrazovat ve zvoleném měřítku dle požadavků uživatele. Načtený soubor lze uložit ve formátu přímo čitelném v prostředí Matlab pro jednodušší další zpracování. Jednotlivé funkce programu jsou popsány níže.



Obr. 9 – Podoba programu AVG IMEX

Program má intuitivní ovládání pomocí lišty s jednotlivými prvky. Po stisku tlačítka *Načíst soubor* se objeví dialogové okno pro vybrání příslušného souboru s příponou DOP. Pokud je vybrán jiný soubor než *.DOP program vypíše chybné hlášení a vyzve uživatele k opětovnému výběru souboru pro zobrazení. Po jeho úspěšném načtení je ihned vykreslen signál v grafickém okně a v poli *Informace o vyšetření* jsou zobrazeny informace doplňující měření v příslušných buňkách. Měřítko obou os jsou v takovém formátu, ve kterém byly v momentě ukládání souboru. Tlačítkem *Změnit rozsah* je možné přepnout formát měřítka osy y. V případě, že je

v jednotkách kHz, na jednotky cm/s a naopak. V poli *Hlášení programu* jsou vždy zobrazovány informace o umístění načteného souboru, popřípadě chybná hlášení.

5.2. Data z projektu GAČR

Jelikož nebylo v rámci tohoto projektu možné sestavit tak rozsáhlou a kompletní vlastní databázi bylo nutné použít ke zpracování databázi již vytvořenou v rámci projektu Grantové agentury České republiky č. 102/95/0785 z roku 1998, [8].

Použitá databáze je dostatečně obsáhlá, skládá se celkově ze 144 měřených pacientů. Její součástí jsou jednak pletysmografická vyšetření, záznamy o pacientech a hlavně soubory signálů a parametrů AVG. Takto vytvořená databáze je navíc i klinicky ověřena. Data jednotlivých vyšetření jsou uložena v databázovém systému FoxPro v2.50 (ve verzi pro DOS). Pro řešení diplomové práce jsou stěžejní především soubory AVG.DBF (obsahuje jednotlivé parametry signálů AVG) a PAC.DBF (uchovává doplňující informace o vyšetřeních včetně anamnézy). Struktury souborů jsou uvedeny v přílohách A, B.

Data uložená ve formátu pro DOS v systému FoxPro v2.50 jsou zcela nevhodná pro zpracování v prostředí Matlab. Z tohoto důvodu bylo nutné všechny soubory rozkódovat a přetransformovat do formátu, s nímž je možné nadále pracovat ve využitém programovém prostředí.

5.3. Transformovaná data do formátu pro Matlab

Data v souboru AVG.DBF kódována v ASCII. Jednotlivé záznamy jsou uloženy za sebou, vždy jeden řetězec dlouhý 107 znaků odpovídající příslušné položce v databázi (ME - měření, PR - průměrné hodnoty, OD - odchylky, VK - variační koeficienty). Tento formát souboru bylo nutné převést do příslušné formy vhodné pro zpracování v prostředí Matlab.

Realizaci tohoto převodu zajišťuje program DB_pacientu.m, jehož vstupem je soubor AVG.DBF a výstupem soubor DB_AVG.mat. Vzhledem k tomu, že soubor má velikost cca 35MB a obsahuje celkem 10047 záznamů, jeho zpracování trvá trochu déle. Podobnou strukturu má i soubor PAC.DBF. Výstup programu realizujícího jeho transformaci je uložen také do souboru DB_AVG.mat. Struktura vytvořeného souboru DB_AVG.mat je uvedena v tabulce. Obsahuje tři položky:

- *db_avg* - má buňkovou strukturu a každá buňka obsahuje jeden záznam ve formě struktury (celkem 10047 buněk), v každé buňce jsou údaje ve formátu podobném, jako ukazuje příloha A;
- *db_avg_cisl* – jedná se o matici obsahující záznamy parametrů signálů AVG v číselném formátu (10047 záznamů);
- *db_anamneza* – má stejnou strukturu jako položka *db_avg*, obsahuje uložené doplňující informace o vyšetřeních (celkem 142 pacientů).

Takto uložené informace bylo nutné roztřídit podle vybraných příznaků, s ohledem na druh záznamu a místo měření. Roztříděná data musí být dále podrobena fázi předzpracování dat, viz následující kapitola 6.

6. Předzpracování dat

6.1. Rozdělení dat a vybrání příznaků

Před vlastním klasifikačním procesem je nutné provést rozřídění dat podle míst měření a podle druhů záznamů. Pro zpracování jsou vybrány pouze položky s typem záznamu PR – tedy vždy průměrné hodnoty z několika měření daného signálu na konkrétním pacientovi. Tímto se do značné míry eliminuje primární chyba, která mohla vzniknout při samotném pořizování signálů.

Dále je nutné z celkové databáze selektovat záznamy pořízené pouze z míst měření, které byly zvoleny pro samotnou klasifikaci. Jedná se o místa, jež mají nejvýznamnější diagnostickou významnost a jsou tedy pro klasifikaci nejvhodnější. Konkrétně se jedná o měřené záznamy na AF - arteria femoralis (tepna stehenní), AP - arteria poplitea (tepna podkolenní) a ATP - arteria tibialis posterior (tepna holenní zadní). Z popsanych míst je nutné provést přípravu dat do formy vhodné pro další zpracování a vyčlenit vzory, které budou tvořit trénovací a testovací množinu.

Z databáze obsahující parametry AVG signálů byly na základě kontroly nezávislosti příznaků a ověření separability vybrány tyto typické parametry (zkratky odpovídají parametrům uvedeným v kapitole 3.1), [8]:

$$f_{\max} \quad f_{\min} \quad A \quad D \quad T_0 \quad PI$$

Parametry jsou vypočítávány z každého místa měření: AF, AP, ATP. Jedná se tedy celkem o 6 parametrů u každého místa měření. Z tohoto důvodu jsou jednotlivé množiny dat rozděleny tak, aby zachovávali příslušnost k danému místu měření. Navíc se ukázalo být vhodné zpracovávat každou jednu dolní končetinu jako celek, tedy sloučit naměřené parametry ze všech míst měření do jednoho vektoru hodnot, [7]. Takto vytvořená množina musí tedy obsahovat všechny tři místa měření na každé noze a je tedy nutné dbát na přítomnost těchto parametrů u každého pacienta. V případě absence AVG signálu z některého místa měření musí být z klasifikace vyřazena celá dolní končetina. Vzniká nám tedy další, čtvrtá množina trénovacích a testovacích dat, jež je označena jako množina LEG. Tato obsahuje 6 parametrů, postupně ze tří míst měření, tj. celkem 18 parametrů z každé končetiny.

6.2. Kontrola neúplných dat a Grubbsův test extrémních odchylek

Dalším nezbytným krokem tedy je kontrola správnosti a úplnosti naměřených dat. Jednak je potřeba všechny parametry zkontrolovat, a ty co nevyhovují nebo nejsou kompletní vyřadit z výběru. Kontrola může být provedena buď prohlédnutím pouhým okem, což by znamenalo projít všechny záznamy a vyřadit ty, jež se nám jeví jako zkreslené nebo neúplné. Takto provedená kontrola je možná u souborů s menším počtem pozorování. V našem případě bylo preferováno řešení pomocí strojové kontroly dat jednak na neúplnost, a jednak na jejich nekorektnost resp. nesmyslnost.

Při kontrole neúplnosti dat jsou zkoumány parametry PI, T_0 , f_{\max} z hlediska jejich nulové hodnoty. Tyto parametry nemohou nabývat nulové hodnoty ani u zcela nemocného jedince. Jedná se tedy o chybové údaje, jež je nutné před vlastním procesem klasifikace ze souboru vyloučit. Tyto chybějící hodnoty nelze nahradit prostým

průměrem dat zbývajících, jelikož by došlo ke značnému zkreslení předložených dat. Klasifikace takových dat by pak nebyla korektní.

Na zbylé záznamy u všech množin dat byla dále aplikována metoda eliminace extrémních hodnot pomocí Grubbsova testu, viz kapitola 4.1.2. Pomocí tohoto testu a algoritmu realizujícího tento test, byly z každého souboru vynechány záznamy, u nichž bylo oprávněné podezření na jejich zkreslení. Extrémní hodnoty zapříčiňují ve výběru opět značné zkreslení a odchylky od normálního rozdělení. Vyřazením těchto hodnot se podstatně zlepšila klasifikační účinnost metod.

6.3. Vyčlenění dat do trénovacích množin

Tab. 1 – Rozdělení vzorů do tříd v trénovacích množinách

Trénovací množina AF - arteria femoralis

1. tř.	pravá st.	42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 58, 59, 66, 67, 68
	levá st.	42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 58, 59, 66, 67, 68
2. tř.	pravá st.	69, 70, 72, 73, 76, 82, 83, 85, 90, 97, 104, 106
	levá st.	70, 73, 74, 75, 76, 77, 78, 79, 82, 88, 89, 90, 92, 85, 100, 101, 106
3. tř.	pravá st.	71, 92, 93, 101, 105
	levá st.	69, 71, 72, 83, 85, 86, 93, 97, 99, 102, 104, 105

Trénovací množina AP - arteria poplitea

1. tř.	pravá st.	42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 58, 59, 66, 67
	levá st.	42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 57, 58, 59, 66, 67, 68
2. tř.	pravá st.	69, 70, 72, 73, 74, 76, 79, 81, 82, 83, 85, 90, 95, 97, 100, 106
	levá st.	70, 73, 74, 75, 76, 77, 78, 79, 80, 82, 88, 90, 92, 100, 101, 106
3. tř.	pravá st.	71, 80, 92, 93, 99, 101, 105
	levá st.	69, 71, 72, 83, 85, 86, 93, 97, 99, 102, 104, 105

Trénovací množina ATP - arteria tibialis posterior

1. tř.	pravá st.	42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 58, 59, 66, 67, 68
	levá st.	42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 58, 59, 66, 67, 68
2. tř.	pravá st.	69, 70, 72, 73, 74, 76, 79, 81, 82, 83, 85, 90, 97, 100, 104, 106
	levá st.	70, 73, 74, 75, 76, 77, 78, 79, 80, 81, 82, 88, 89, 90, 92, 100, 101, 106
3. tř.	pravá st.	71, 80, 92, 93, 99, 101, 105
	levá st.	69, 71, 72, 83, 85, 86, 93, 97, 99, 102, 104

Trénovací množina LEG - AF + AP + ATP

1. tř.	pravá st.	42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 58, 59, 66, 67
	levá st.	42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 54, 55, 57, 58, 59, 66, 67, 68
2. tř.	pravá st.	69, 70, 72, 73, 76, 82, 83, 85, 90, 97, 106
	levá st.	70, 73, 74, 75, 76, 77, 78, 79, 82, 88, 90, 92, 100, 101, 106
3. tř.	pravá st.	71, 92, 93, 99, 101, 105
	levá st.	69, 71, 72, 83, 85, 96, 93, 97, 99, 102, 104


Po vytříbení původní databáze dat bylo nutné vyčlenit z testovacích množin vzory, jež budou použity jako tzv. trénovací množiny. K tomuto účelu je nutná konzultace s expertem, tedy v tomto případě kvalifikovaným angiologem. Vzory trénovací množiny byly tedy převzaty z projektu GAČR, [8]. Strukturu trénovacích množin ukazuje souhrnná Tab. 1. Označení jednotlivých tříd je zachováno v souladu

s [8], tedy 1. třída označuje zdravé pacienty, 2. třída pacienty se stenózami a 3. třída pacienty s uzávěry cév dolních končetin.

6.4. Test normality rozdělení dat

U vytvořených množin dat je nadále nutné ověřit, zda soubory pocházejí z výběrů s normálním rozdělením. Každý z příznaků f_{\min} , f_{\max} , A, D, T_0 a PI v každé množině AF, AP a ATP byly podrobeny jednorozměrným testům ověřujících tento předpoklad, tedy hypotézu H_0 , že výběry mají normální rozdělení. K ověření normality jsou zde využity jednorozměrné testy šikmosti a špičatosti. Jak bylo uvedeno v 4.1.1, jsou testy ověřující normalitu velmi citlivé na jakoukoli odchylku od předpokladu normálního rozložení. Z tohoto důvodu jsou hypotézy testovány na hladině významnosti $\alpha = 0,001$.


Algoritmy testů normality jsou realizovány programem statistika_normalita.m, jehož vstupem je soubor obsahující příslušné vstupní matice dat, na nichž má být proveden test. Výstupem tohoto programu je série grafů popisujících jednotlivé příznaky v testovaných souborech. Pro přehledné zobrazení a zachycení problému byl zvolen grafický výstup v podobě q-q grafu rozdělení, což ukazuje Obr. 10, Obr. 11 a Obr. 12. Jedná se o grafy, u nichž lze snadno získat představu o tom, zda výběr může pocházet z daného (zde normálního) rozdělení. Červená linka určuje teoretické rozložení a modré body jsou body testovaného výběru. Podle tvaru spojnice trendů bodů lze usuzovat na odchylky od testovaného rozložení.




Obr. 10 – Ověření normality souboru testovací množiny AF (a. femoralis)

U testu množiny AF (Obr. 10) je vidět, že nebyly odhaleny žádné významné odchylky od normality ani u jednoho parametru. To je důležité, jelikož úsek arterie femoralis má nejvyšší klinickou významnost při posuzování na rizika přítomnosti ICHDK. Je třeba znovu zdůraznit, že testy jsou prováděny na poměrně nízké hladině významnosti. Jinak je tomu již u testu množiny AP (Obr. 11) a ATP (Obr. 12). Zde bylo testem odhaleno, že parametr D, zpomalení systolické vlny, nepochází z výběru s normálním rozložením. Koeficienty šikmosti a špičatosti se zde významně liší od

předpokladu příslušejícímu normálnímu rozložení, viz vztah (15). Tuto odchylku lze akceptovat vzhledem k menší klinické významnosti tohoto parametru při klasifikaci oproti například velmi významným parametrům PI a T_0 .



Obr. 11 – Ověření normality souboru testovací množiny AP (a. poplitea)



Obr. 12 – Ověření normality souboru testovací množiny ATP (a. tibialis posterior)

7. Navržené způsoby klasifikace

Po prostudování problematiky zabývající se klasifikací jako takovou a konkrétními případy popsány v [6] byly vybrány dva způsoby analýzy pro realizaci této diplomové práce. Konkrétně jsou to metody klasifikace pomocí vícerozměrných statistických metod a využití neuronových sítí.

7.1. Klasifikace pomocí vícerozměrných statistických metod

7.1.1. Redukce dat pomocí metody hlavních komponent

Redukce dat při využití vícerozměrných statistických metod je často jejich nezbytnou součástí. Výpočty velkých objemů dat bývají náročné. Při dnešním stavu výpočetní techniky by se mohlo zdát, že tato metoda redukce dat z části postrádá smysl. Ovšem transformace původních parametrů na hlavní komponenty má i jiný účel, a to ve smyslu umožnění grafické interpretace dat s vysokým obsahem původní informace.

Zde byla metoda hlavních komponent aplikována na všechny testovací množiny a z nich byly nadále vybrány trénovací vzory. Redukce dat se uplatnila především při aplikaci na množinu LEG, která obsahuje původních 18 parametrů. Po aplikaci algoritmů na testovací data bylo zjištěno, že množství informace popsané ve třech prvních hlavních komponentách se pohybuje nad hodnotou 98%. Konkrétně u množiny AF je obsah původní informace v prvních třech hlavních komponentách 98%, u množiny AP 99% a u množiny ATP také 99%. U množiny LEG je to již poněkud méně. Je to způsobeno množstvím původní informace v jednom vektoru, který obsahuje 18 příznaků. V tomto případě se pohybuje množství informací kolem hodnoty 90%, také ve třech prvních hlavních komponentách. I tato hodnota je ovšem z hlediska statistické analýzy postačující. Soubor se vstupní množinou dat se tedy může zredukovat na tříparametrovou matici, již je navíc snadné graficky interpretovat.

7.1.2. Vlastní analýza testovacích dat pomocí shlukové analýzy

Shluková analýza jako taková je jednou z metod klasifikace či rozpoznání obrazu učení bez učitele. Takto se využívá při předložení neznámých, nezařazených souborů dat, u kterých primárně chceme nalézt společné vlastnosti a co nejvhodněji je sloučit do shluků. Ovšem tuto metodu lze s úspěchem aplikovat i jako metodu klasifikace dat s učitelem za předpokladu, že máme k dispozici ověřené trénovací množiny. V našem případě je využito právě druhého případu.

Tab. 2 – Rozdělení pacientů do tříd podle stupně stenózy a přiřazení čísla shluku

Třída	Zařazení	Stenóza (%)	Index shluku
1.	osoby zdravé	0 ÷ 19	1
2.	pacienti se stenózami	20 ÷ 79	2
3.	pacienti s uzávěry	80 ÷ 100	3

Data pro využití klasifikačních algoritmů shlukové analýzy musejí mít proto určité uspořádání. Vstupní hodnoty tvoří matice redukovaných dat metodou hlavních komponent (vždy první tři hlavní komponenty pro všechny záznamy z dané množiny). Ovšem pro aplikaci metodiky klasifikace s učitelem je nutné předložit také vzory

zařazení jednotlivých pozorování trénovací množiny. Proto je nutné ke vstupním datům trénovací množiny navíc přiložit jako vstup vektor určující, do které třídy daný vzor náleží. Označení shluků je uvedeno v Tab. 2.

V případě, máme-li k dispozici jako vstup vhodně naformátovaná data, můžeme přistoupit k vlastní klasifikaci. Jak již bylo uvedeno, AVG signály jsou charakteristické vysokou variabilitou nejen vzhledem k fyziologickým faktorům, ale i vzhledem k fyzikální podstatě snímání signálů. Hranice mezi klasifikačními třídami nejsou tedy ostré a třídy se často prolínají. Praktickým zkoumáním a ověřováním byla zjištěna jako nejvhodnější metoda klasifikace pomocí shlukování využívající přiřazení do třídy pomocí nejbližšího souseda. V případě nejbližšího souseda jsou třídy reprezentovány svými typickými představiteli, trénovací množinou. V procesu klasifikace se pak nový příklad zařadí do třídy na základě podobnosti (nejmenší vzdálenosti k reprezentantovi nějaké třídy). Jde tedy o metodu, která vychází ze shlukové analýzy. Klíčovým pojmem je koncept podobnosti, resp. vzdálenosti dvou příkladů. Jak bylo uvedeno v kapitole 4.1.4, jsou neužívanější metriky pro určení vzdálenosti Mahalanobisova a Eukleidova. I zde je podobnost příkladu se vzorem určena na základě Eukleidovy metriky.


7.1.3. Klasifikace užitím vícerozměrných statistických metod - Program Clustering

Popsané postupy v předchozí kapitole byly využity při realizaci programové podoby teoretických algoritmů. K vývoji uživatelské aplikace bylo využito prostředí Matlab GUI. Vytvořený program Clustering je jednoduchý na užívání. Jeho podoba je vyobrazena na Obr. 13. Jako vstup se zde v poli *Vstupní data* volí jedna z množin AF, AP, ATP a LEG. Zvolená položka neuložena do paměti programu a slouží jako index pro volbu vstupních dat. Podle tohoto indexu jsou načtena příslušná vstupní data jak trénovací množiny (včetně vektoru zařazení této množiny), tak i množiny testovací. Takto předložená data jsou poté po stisku tlačítka *Analýza* podrobena klasifikačním algoritmům realizujícím postupy uvedené výše. Výsledkem jsou dva grafy, v levé části graf zobrazující trénovací množinu, a v pravé části graf prezentující výsledky klasifikace, přičemž zelená barva zde reprezentuje správně zařazený prvek a červená barva analogicky nesprávně klasifikovaný prvek. Pro lepší představu o podobě složení trénovací a klasifikované množiny lze při zobrazení v poli *Volba zobrazení* volit mezi 2 nebo 3 hlavními komponentami.

Nesdílňou součástí klasifikace především biomedicínských dat je také určení parametrů popisujících úspěšnost metody. Jedná se o parametry senzitivity (41) a specificity (42), jak byly definovány v kapitole 4.3. Tyto jsou počítány při každé klasifikaci a jsou v patřičné formě v programu zobrazeny. Doplnujícím hodnotícím parametrem klasifikace je procentuální vyjádření chybných klasifikací metody, jež je zobrazeno v poli *Chybná zařazení*. Tento parametr udává, kolik procent z celkových předložených pozorování bylo při klasifikaci zařazeno do jiné třídy, než byla určena pomocí kontrolní metody.

Pomocí menu a volby položky *Pacientská data* je zde možno spustit modul, pomocí něhož lze zobrazit data podílející se na klasifikaci v závislosti na volbě pacienta. Takto zobrazené informace slouží jako kontrola výsledků klasifikace. Podrobnější popis tohoto modulu je uveden v kapitole 7.3. Výsledky klasifikace lze pomocí menu a položky *Tisk* vytisknout.

Jednotlivé výsledky aplikací vícerozměrných statistických metod jsou souhrnně prezentovány v kapitole 8. Graficky znázorněné klasifikace jsou uvedeny v příloze C.



Obr. 13 – Program Clustering, výsledky klasifikace množiny LEG

7.2. Klasifikace užitím neuronových sítí

7.2.1. Navržená topologie sítě

Topologie vícevrstvé perceptronové sítě byla experimentálně volena jako jednovrstvá, dvouvrstvá a třívrstvá. Jak již bylo uvedeno v kapitole 4.2.4, počet neuronů vstupní vrstvy je určen počtem vstupujících příznaků. U množin AF, AP a ATP je to tedy 6 vstupních příznaků, tedy 6 vstupních neuronů. U množiny LEG je počet vstupních neuronů potom 18. Počet výstupních neuronů pak určuje počet klasifikačních tříd. V našem případě má neuronová síť ve výstupní vrstvě vždy 3 neurony. Struktura vnitřních vrstev pak může být volena takřka libovolně. Je nutné dodržet podmínku, že počet neuronů ve skryté vrstvě musí být menší, než počet neuronů ve vstupní vrstvě a větší než počet neuronů ve výstupní vrstvě.

S ohledem na tyto omezení byly experimentálně voleny topologie neuronové sítě v závislosti na schopnosti učení a na výsledné přesnosti klasifikace. Pro klasifikaci množin AF, AP a ATP se jako nejvhodnější ze zkoušených topologií jevíly:

- topologie T1: 6-4-3
- topologie T2: 6-5-3
- topologie T3: 6-3-5-3
- topologie T4: 6-3-6-3

Pro množinu LEG to potom jsou sítě s topologiemi:

- topologie T5: 18-10-3
- topologie T6: 18-10-4-3
- topologie T7: 18-15-8-3
- topologie T8: 18-10-6-4-3

7.2.2. Forma vstupních dat pro síť

Vstupní data pro neuronovou síť musí být správně upraveny, aby s nimi mohla síť korektně pracovat. Nejjednodušší situace, v našem případě, nastává při simulacích statické neuronové sítě. Není potřeba se zabývat časovým sledem předkládaných vektorů dat, vstupy sou předkládány simultánně. Při zpracování neuronovou sítí se nevyužívá redukce dat pomocí hlavních komponent, a tak jsou vstupní vektory sítě tvořeny přímo parametry signálů AVG. Vstupní data jednoho vektoru tvoří 6 příznaků u množiny AF, AP, ATP, resp. 18 příznaků u množiny LEG. Tyto jednotlivé vektory jsou pak síti předloženy jako jedna matice, ve které řádky odpovídají jednotlivým příznakům, a sloupcové vektory tvoří jednotlivá pozorování. Takto sestavená matice může být předložena na vstup síť, přičemž nezáleží na pořadí sloupcových vektorů v matici, protože tyto mezi sebou neinteragují.

K tomu, aby se mohla síť naučit klasifikaci, je nutné předložit jí nejdříve trénovací vzory. Jedná se opět o množiny, jak byly definovány v Tab. 1, tentokrát upravené do formy akceptované sítě. K tomu je potřeba zároveň síti předložit tzv. matici cílových hodnot (targets) korespondující s předloženými vzory (patterns). Struktura této matice se odvíjí od počtu výstupních neuronů, tedy počtu klasifikačních tříd. Konkrétně jsou jednotlivé vektory zde definovány podle Tab. 3, kde vždy jeden vektor z matice cílů odpovídá příslušnému jednomu vektoru z matice vzorů.

Tab. 3 – Rozdělení pacientů do tříd podle stupně stenózy a přiřazení výstupního vektoru

Třída	Zařazení	Stenóza (%)	Cílový vektor trénovací matice
1.	osoby zdravé	0 ÷ 19	1 - 0 - 0
2.	pacienti se stenózami	20 ÷ 79	0 - 1 - 0
3.	pacienti s uzávěry	80 ÷ 100	0 - 0 - 1

7.2.3. Učení neuronové sítě

Učení neuronové sítě se provádí pomocí algoritmu back-propagation. Samotný proces učení je nejvíce závislý na zvolené topologii sítě a počátečním nastavení vah. Při vhodně zvolené topologii energie sítě konverguje k požadované přednastavené přesnosti a síť se tak učí. Zvolíme-li však topologii nevhodně, může dojít k tomu, že pokles energie sítě se zastaví a dojde k uvíznutí v tzv. lokálním minimu. Síť se tak nikdy daný vzor nenaučí. Máme k dispozici několik postupů, kterými můžeme uvíznutí v lokálním minimu řešit.


Mezi ně patří vhodná volba strategie výběru vzorů z trénovací množiny (např. náhodně) a vhodná volba počátečních hodnot vah, které jsou generovány také náhodně v určitém rozsahu. Významnými parametry pro učení sítě, které můžeme snadno měnit,

jsou především momentum (setrvačnost) a koeficient učení. Pokud zvolíme větší hodnotu koeficientu učení, bude krok tak velký, že lokální minima přeskočíme. Na druhou stranu příliš velká hodnota vede k nežádoucím oscilacím. O něco účinnější je vhodná volba momentu sítě, která přidává do postupu váhovým prostorem setrvačnost. Pokud se tedy síť dostane do lokálního minima a bude mít dostatečnou setrvačnost, udrží si stejný směr, jakým se do lokálního minima dostala i přes nárůst energie. Tyto parametry se volí v rozsahu $<0,1>$.

Ukázka některých parametrů, které lze před zahájením procesu učení nastavovat je zde uvedena ve formátu, se kterým pracuje Neural Network Toolbox v prostředí Matlab (část zdrojového kódu programu NN).

```
% Nastavení parametrů trénování
net.trainParam.epochs = handles.epochs; % maximální počet epoch
net.trainParam.time = handles.time;      % maximální doba trénování
net.trainParam.goal = handles.goal;       % požadovaná přesnost
net.trainParam.lr = handles.lr;           % koeficient učení
net.trainParam.show = 10;                 % počet epoch mezi zobrazením
chyby                                     %
net.trainParam.time = 100;                % maximální doba učení
net.trainParam.mu = handles.mu;           % koeficient chyby
net.trainParam.mc = handles.mc;           % momentum (setrvačnost)
net.trainParam.max_perf_inc = 100;        % inkrement maximálního výkonu
net.trainParam.min_grad = 0;              % minimální gradient
net.trainParam.mem_reduc = 1;             % redukce nároků na systémovou
                                         paměť
```

Na Obr. 14 je ukázán průběh učení sítě o topologii 6-4-3 při učení na vzorech trénovací množiny AF. Nastavení parametrů pro učení bylo: koeficient učení 0,4; momentum 0,9; koeficient chyby 0,03; inkrement maximálního výkonu 100. Je zde vidět, že takto zvolené parametry učení vedly velmi rychle k naučení sítě na požadovanou přesnost $1e-8$, síť by v tomto případě byla schopna naučit se vzory i s menší chybou.




Obr. 14 – Průběh energie sítě během učení na trénovací množině AF

Je nutno podotknout, že všechny stěžejní parametry učení jsou silně závislé na trénovací množině. Zjištění optimálních hodnot pro danou trénovací množinu je otázkou experimentu. Navíc je někdy nutné trénování sítě několikrát opakovat, než se síť předkládané vzory správně naučí, popřípadě vytvořit síť novou se stejnou topologií a proces trénování zahájit znovu.

7.2.4. Klasifikace pomocí neuronových sítí - Program NN

Optimální volba topologie sítě je závislá na řešené úloze. Proces, který vede k zjištění takové struktury sítě je mnohdy otázkou experimentů. Bylo tedy nutné testovat jednotlivé topologie sítě jednak z hlediska možnosti jejich učení, jednak z pohledu jejich výsledku při klasifikaci. K zjednodušení nastavování topologií sítí a jednotlivých parametrů byl vytvořen program NN, který slouží i jako koncový nástroj při klasifikaci množin AVG signálů. Při jeho návrhu bylo také využito uživatelské vývojové prostředí GUI vývojového programu Matlab. Podoba programu NN je zachycena na Obr. 15. Program má podobné ovládání jako program Clustering. Jsou zde ovšem zahrnuty další ovládací prvky pro ovládání programu, které umožňují nastavovat rozličné parametry neuronové sítě.

Načtení vstupních dat se provádí volbou z menu *Vstupní data* v levé dolní části programu. Zde je i položka volba zobrazení, pomocí které lze přepínat mezi zobrazením ve 2D prostoru a 3D prostoru. Jak již bylo uvedeno, neuronové sítě zpracovávají původní parametry a ne hlavní komponenty. K zobrazení ve dvourozměrném prostoru byly tedy zvoleny stěžejní parametry PI reprezentující osu x, parametr T_0 zastupující osu y a při volbě trojrozměrné prezentace parametr f_{\max} , který zde zastupuje osu z. Při zobrazení množiny LEG, jež má celkem 18 parametrů, jsou využity stejné parametry z místa měření AF.



Obr. 15 – Program NN, výsledky klasifikace množiny ATP

Volba topologie sítě se provádí v poli *Vytvoření sítě* pomocí nastavení parametrů *Počet vrstev*, počet neuronů v každé vrstvě a volba aktivační funkce neuronů. Počet vstupních neuronů je automaticky nastaven na hodnotu odpovídající množství příznaků zastupujících danou množinu, počet výstupních neuronů je vždy nastaven na 3. Po zvolené topologii se tlačítkem *Vytvořit síť* jednak daná síť zrealizuje, jednak jsou aktivovány další ovládací prvky programu pro další postup při klasifikaci.

Dalším krokem je nastavení parametrů pro učení sítě. Tyto lze měnit v poli *Trénování sítě*. Jsou zde k dispozici pouze stěžejní nastavení sítě jako *Maximální počet epoch*, *Koeficient učení*, *koeficient chyby*, *Požadovaná přesnost* a *Momentum (setrvačnost)*. Vlastní trénování sítě je zahájeno stiskem tlačítka *Trénovat*. Objeví se nové okno (viz Obr. 14), kde lze sledovat průběh energie sítě při jejím učení v závislosti na počtu epoch a hodnotu chyby, které má být dosaženo. Trénování lze ukončit stiskem tlačítka *Stop training* v tomto okně. Pro ověření zda se síť předložené vzory naučila je zde funkce *Simulovat natrénování*. Po stisku tohoto tlačítka se pravém grafickém okně zobrazí vzory z trénovací množiny, jež byly klasifikovány do tříd zvolenou sítí. Pokud byla síť korektně naučena s dostatečně malou chybou, musí být výsledek klasifikace absolutně správný, tedy nedojde k žádnému chybnému zařazení.

Poslední fází je vlastní klasifikace testovací množiny dat. V pravém dolním rohu je pole simulace sítě a v něm mimo jiné tlačítko *Simulovat*. Volbou toho tlačítka se provede načtení testovacích dat na vstup sítě a provede jejich klasifikace. Výsledky procesu jsou zachyceny v pravém grafickém okně, zelená barva zde značí správně klasifikovaný prvek, červená barva naopak jeho nesprávné zařazení. K souhrnnému hodnocení jsou zde opět zobrazeny parametry senzitivity a specifity počítané při každé klasifikaci.

Kontrolu klasifikace je i zde možno provést spuštěním modulu *Pacientská data* z horního menu (popis v následující kapitole). Volbou položky *Tisk* z *Menu* lze zachytit podobu programu pomocí tisku.

Výsledky aplikací neuronových sítí jsou shrnuty v kapitole 8. Graficky znázorněné klasifikace jsou uvedeny v příloze D až G.

7.3. Modul Pacientská data

Tento modul je dostupný pouze po provedené klasifikaci a lze ho spustit položkou horního menu *Pacientská data*. Po jeho spuštění je zobrazena prázdná „pacientská karta“. V závislosti na zvolené analyzované množině jsou, v pravém dolním rohu, zobrazeny identifikační čísla pacientů z databáze, kteří byli zařazení do klasifikace příslušného souboru. Pomocí menu *Zobrazit* lze zvolit zobrazení identifikačních čísel pacientů z klasifikované množiny, kteří byli klasifikováni správně. ID těchto záznamů se zobrazí zelenou barvou. Podobně lze vybrat zobrazení pacientů, kteří byli zařazení do nesprávné třídy. Tyto jsou zobrazeny barvou červenou. Poslední položkou z menu *Zobrazit* je volba zobrazení všech záznamů zařazených do klasifikace aktuální množiny.

Volbou z nabídky *ID pacienta* dojde k zobrazení informací zaznamenaných při vyšetření pacienta, jako jsou identifikační údaje, záznamy z vyšetření a anamnéza. V levé dolní části jsou zobrazeny všechny určené parametry AVG signálů rozdělené podle místa snímání. Právě tyto parametry se podílejí na klasifikaci. Dále jsou zde v poli *Klasifikace* k dispozici informace určující, zda byl pacient zařazen do klasifikace aktuálního souboru. Je zde k dispozici porovnání výsledku klasifikace se zařazením pacienta do třídy pomocí DSA. Uživatel si tak může zobrazit ID pacientů, kteří byli

klasifikování nesprávně, a v závislosti na nich zvolit zobrazení informací těchto pacientů. Podle načtených údajů lze následně získat představu o zařazení pacienta do příslušné třídy. Vzhled tohoto modulu je na Obr. 16.

Pacientská data - AF+AP+ATP

Soubor Zobrazit

Administrativní údaje

ID pacienta: 97

Příjmení: DRATVA

Jméno: DALIBOR

Rodné číslo: XXXXXXXXXX

Datum narození: 27.07.1940

Věk: 57 Pohlaví: M

Měření

Datum měření: 01.09.1997

Výška: 178cm Váha: 80kg

DX-prava strana SIN-leva strana

K.T. - a. brachialis: 180mmHg

K.T. - a. poplitea: 186mmHg 159mmHg

K.T. - a. tibialis posterior: 181mmHg 141mmHg

K.T. - a. tibialis anterior: 165mmHg 119mmHg

Teplota: 28.1C 28.1C

Urcené hodnoty parametru

Místo	Strana	Fmax	Fmin	A	D	T0	PI
AIE	DX	2.557	-0.512	62.478	-10.209	135.400	8.220
AF	DX	1.552	-0.919	14.478	-18.765	134.300	14.080
AIE	SIN	2.084	0.591	38.858	-10.995	126.300	1.940
AF	SIN	1.016	-0.147	11.691	-7.631	136.100	7.760
ATP	DX	1.328	-0.505	25.384	-8.747	211.100	20.770
ATA	DX	0.920	-0.429	13.330	-10.851	212.600	29.440
ATP	SIN	0.309	-0.021	6.359	-4.091	235.100	6.250
ATA	SIN	0.239	-0.019	2.830	-5.136	286.200	9.060
AP	DX	0.612	-0.352	16.558	-7.109	177.600	15.380
AP	SIN	0.239	-0.043	6.767	-1.089	189.400	6.080

Anamnéza

Diabetes: ☐ Diabetes let: 0

Hypertenze: ☐ Hypertenze let: 0

Genetická zátěž: ☐

Cevní operace: ☐

Srdeční onemocnění: ☐

Angina pectoris: ☐

Varixy: ☐

Kouření: ☒ Kouření let: 20

Kouření denne: 1

Klaudikace vlevo (sin.): ☒ Kl. vzdálenost: 5

Klaudikace vpravo (dx.): ☐ Kl. vzdálenost: 0

Stenóza vlevo (sin.): 99

Stenóza vpravo (dx.): 0

Klasifikace

Zařazen do klasifikace: ☒ DX-prava strana: 2 SIN-leva strana: 3

Zařazení podle DSA: DX-prava strana: 2 SIN-leva strana: 3

Pacienti zařazení do klasifikace množiny - AF+AP+ATP

DX 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56

58 59 66 67 69 70 71 72 73 75 76 77 82 83 85

86 88 89 90 92 93 96 97 99 101 102 105 106 109

112 113 116 118 119 120 123 124 125 126 127 129 130

132

SIN 42 43 44 45 46 47 48 49 50 51 52 54 55 57 58

59 66 67 68 69 70 71 72 73 74 75 76 77 78 79

82 83 85 86 87 88 90 92 93 96 97 99 100 101

102 104 106 109 110 111 112 114 115 116 117 119 120

121 122 123 125 126 127 129 130 131 132 133

Obr. 16 – Modul Pacientská data zobrazující údaje z vyšetření

8. Porovnání výsledků klasifikace užitých metod

V této kapitole jsou shrnuty výsledky, jichž bylo dosaženo při aplikaci obou uvedených metod - klasifikace pomocí vícerozměrných statistických metod a využitím neuronových sítí. Tab. 4 udává dosažené parametry senzitivity, specifity a procentuální chybu nesprávných zařazení (označení T1-T8 bylo definováno v kapitole 7.2.1, C symbolizuje metodu shlukování - clustering). Aby bylo možno tyto parametry určit, musíme mít k dispozici výsledky ověřené referenční metodou. V našem případě se konkrétně jedná o digitální subtrakční angiografii (DSA), [8].

Tab. 4 – Výsledky klasifikace: parametry senzitivity a specifity, chyba metody

klasifikovaná množina	metoda/ topologie	C	T1	T2	T3	T4
AF	TP	24	24	24	22	27
	TN	40	40	40	40	40
	FP	5	5	4	2	7
	FN	5	1	4	1	1
	senzitivita [%]	82,75	96,00	92,59	95,65	96,42
	specifita [%]	88,88	88,88	90,90	95,23	85,10
	chyba zařazení [%]	15,32	13,13	12,40	13,13	13,13
AP	TP	29	34	34	31	33
	TN	39	39	39	39	39
	FP	6	7	7	14	9
	FN	2	4	9	5	4
	senzitivita [%]	93,54	89,47	79,06	86,11	89,18
	specifita [%]	86,66	84,78	84,78	73,58	81,25
	chyba zařazení [%]	13,10	11,72	15,17	18,62	13,79
ATP	TP	30	30	31	27	32
	TN	42	42	42	42	42
	FP	10	8	12	4	8
	FN	3	6	2	1	3
	senzitivita [%]	90,90	83,33	93,93	96,42	91,42
	specifita [%]	80,76	84,00	77,77	91,30	84,00
	chyba zařazení [%]	14,28	14,28	14,28	10,88	11,56

klasifikovaná množina	metoda/ topologie	C	T5	T6	T7	T8
LEG	TP	26	31	30	32	31
	TN	38	38	38	38	38
	FP	6	5	8	9	14
	FN	2	8	3	3	1
	senzitivita [%]	90,90	79,48	90,90	91,42	96,87
	specifita [%]	80,76	88,3,7	82,60	80,85	73,07
	chyba zařazení [%]	12,69	11,90	11,90	11,11	14,28

Při aplikaci shlukové analýzy byla experimentálně jako nejvhodnější zvolena metoda nejbližšího souseda. Podobně se ukázalo být nejúčelnější použití Eukleidovy metriky pro měření vzdáleností jednotlivých pozorování. Jako nejúčinnější se ukázalo klasifikovat parametry z celé končetiny najednou (množina LEG). Klasifikací dílčích

míst měření AF, AP a ATP je dosaženo poněkud vyšší chyby klasifikace. Z hlediska senzitivity a specificity se jako nejvhodnější ukázalo klasifikovat samotnou množinu AP, kdy tyto parametry dosahují hodnot 93,54 % pro senzitivitu a 86,66 % pro specificitu.

Z výsledků klasifikace pomocí neuronových sítí je patrné, jak moc jsou citlivé právě na zvolenou topologii. Nejnižší chyby při klasifikaci bylo dosaženo pomocí neuronové sítě o topologii T3 při aplikaci na množinu ATP, a to 10,88 %. Senzitivita je 96,42 % a specificita 91,30 %. Tato topologie ovšem není ideální, jelikož při její aplikaci na množinu ATP bylo dosaženo nejvyšší chyby 18,62 %. Ze souhrnných výsledků lze potom usuzovat, že při aplikaci jedné topologie na všechny tři analyzované množiny (AF, AP, ATP), můžeme za nejvhodnější topologie považovat T1 a T4. V případě množiny LEG se pak jako nejvhodnější jeví topologie sítě T6 a T7 s chybou pod 12 %. Dosažená senzitivita se pohybuje okolo 91 % a specificita okolo 82 %.

Srovnání naznačuje, že použité metody jsou za určitých podmínek rovnocenné. Nejnižší chyby zařazení dosahuje metoda pomocí shlukování (použita Euklidova metrika) u množiny LEG, tedy v případě, hodnotíme-li každou DK jako celek. Chyba v tomto případě dosahuje hodnoty 12,69 %, parametry senzitivity a specificity pak 90,90 % respektive 80,76 %. Se srovnatelnými výsledky byly v tomto případě aplikovány neuronové sítě o topologiích T6 a T7. Z pohledu na dílčí dosažené hodnoty klasifikací jednotlivých množin je použití neuronových sítí vhodné topologie mnohdy lepší variantou, jak z hlediska chyby klasifikace, tak i senzitivity a specificity.

Několikrát již bylo uvedeno, že biologická data jsou velmi nespecifická, a že disponují značnou variabilitou. Při klasifikaci do shluků se toto projevuje především u pacientů, kteří jsou na rozhraní mezi jednotlivými třídami - zdraví, pacienti se stenózami a pacienti s uzávěry. Pak je pro strojové zpracování složité s uvážením volit, do které třídy pacienta klasifikuje. V tomto případě je výhodou neuronových sítí ta vlastnost, že se neřídí podle striktních algoritmů, ale že se umí přizpůsobit řešenému problému a mohou tak dosáhnout lepších výsledků.

Na základě dosažených výsledků můžeme tedy konstatovat, že klasifikace pomocí neuronových sítí je ve srovnání s klasifikací využívající vícerozměrné statistické metody sofistikovanější procedurou. Navíc při dnešní úrovni hardwarového a softwarového vybavení je i relativně snadná její realizace.

9. Zhodnocení dosažených výsledků

Cílem a snahou při řešení předložené diplomové práce bylo seznámit se s metodikou snímání signálů AVG na diagnostickém systému IMEXLAB 9000. Prostřednictvím tohoto přístroje bylo získáno několik záznamů signálů AVG pro určení výstupního formátu souborů a na jejich základě sestaven jednoduchý program umožňující následné základní zobrazení v prostředí Matlab.

Další snahou bylo seznámit se s běžnými metodami analýzy těchto dat. Ze známých způsobů analýzy byly zvoleny metody klasifikace signálů vícerozměrnými statistickými metodami a postup využívající neuronové sítě. Jako vstupní data pro klasifikaci byly použity signály z projektu Komplexní funkční diagnostika cév dolních končetin GAČR z roku 1998. Jelikož jsou použita data uložena v jiném formátu, než je běžný formát prostředí Matlab, bylo je nejdříve nutné pro další zpracování převést do vhodné formy akceptované vývojovým prostředím.

Signály byly podrobeny předzpracování pomocí testu na extrémní odchylky a kontroly normality testem šikmosti a špičatosti vícerozměrného rozdělení. Dále byly roztrženy do jednotlivých testovacích množin podle místa měření na a. femoralis (AF) obsahující 137 záznamů, a. poplitea (AP) se 145 záznamy a a. tibialis posterior (ATP) s počtem záznamů 147. Celkový počet hodnocených parametrů je u každé množiny 6. Jako čtvrtá byla vytvořena množina LEG obsahující záznamy z celé jedné končetiny (celkem 126 záznamů a 18 hodnocených parametrů). Rozdělení vzorů do jednotlivých tříd trénovacích množin je uvedeno v Tab. 1.

Principiálně byl navržen klasifikační algoritmus pro metodu vícerozměrných statistických metod a na jeho základě realizován program Clustering. Výsledky klasifikace byly ověřovány na různých přístupech tvorby shluků. Nejvhodnějším přístupem se ukázal postup přiřazování ke shluku pomocí metody nejbližšího souseda. Stejně bylo experimentálně vyhodnoceno jako nejvhodnější použití Eukleidovy metriky pro měření vzdáleností. Jako hodnotící parametry jsou využity senzitivita, specifická a chyba zařazení. Dosažené výsledky klasifikace jsou uvedeny v Tab. 4. Metoda vykazuje chybu zařazení signálů v rozmezí 12,69 % a 15,32 %. Senzitivita se pohybuje mezi hodnotou 82,75 % a 90,90 %, specifická pak mezi 80,66 % a 88,88 %.

Druhým přístupem ke klasifikaci bylo využití neuronových sítí. Opět byl nejdříve vypracován teoretický koncept zpracování dat pomocí této metody a na jeho základě sestaven program NN realizující uvedené postupy. Volbou topologie sítí a vhodným nastavením parametrů pro učení byly experimentálně ověřeny možnosti klasifikace pomocí přístupu. Z údajů Tab. 4 plyne, že využití neuronových sítí je nepochybným přínosem pro klasifikaci AVG signálů. Tři ze zvolených topologií dosáhli chyby zařazení kolem 11 %, což vzhledem k počtu využitých znaků pro klasifikaci lze považovat jako velmi dobré výsledky. Hodnoty senzitivity jsou v rozmezí 79,06 % až 96,87 % a hodnoty specifity mezi 73,07 % a 91,30 %.

Dosažené výsledky potvrzují realizovatelnost navržených postupů neinvazivní diagnostiky ICHDK. Tyto postupy mohou vést ke zvýšení účinnosti diagnostických metod aplikovaných při diagnostice především rané formy ischemické choroby dolních končetin, převážně u rizikových pacientů.

Použitá literatura

- [1] BAŠTINEC, J., ZAPLETAL, J. *Statistika, pravděpodobnost, operační výzkum*. Brno: 2007. s. 1-161. ISBN: MAT0801.
- [2] DEMUTH, H., BEALE, M., HOGAN, M. THE MATHWORKS, Inc. *Neural Network Toolbox™ 6 User's guide*. 1992-2008. 907s. Dostupné z WWW: <http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf>.
- [3] DRÁBEK, O., SEIDL, P., TAUFER, I. CHEMagazín. *Umělé neuronové sítě – základy teorie a aplikace* (3). 2006, roč. 16 č. 1, s. 12-14.
- [4] HEBÁK, P., HUSTOPECKÝ, J. *Vícerozměrné statistické metody s aplikacemi*. Praha: SNTL - ALFA, 1987. 456 s.
- [5] NOVÁK, M. a kol. *Umělé neuronové sítě. Teorie a aplikace*. Praha: C.H.BECK, 1998. 382 s. ISBN 80-7179-132-6.
- [6] ROZMAN, J., et al. *Elektronické přístroje v lékařství*. 1. vyd. Praha: Academia, 2006. 408 s. ISBN 80-200-1308-3.
- [7] ROZMAN, J. *Klasifikace AVG signálů vícerozměrnými statistickými metodami*. Brno, 1988. 183 s. Dizertační práce. ISBN 80-214-033-7.
- [8] ROZMAN, J., ZONA, M., ŽÁK, J., SOUČEK M. *Komplexní funkční diagnostika cév dolních končetin*. Brno: CERM, 1998. 74 s., 36 př. ISBN 80-7204-063-4.
- [9] ŠNOREK, M., JIŘINA, M. *Neuronové sítě a neuropočítače*. Praha: Vydavatelství ČVUT, 1996. 124 s. ISBN-80-01-01455-X.
- [10] VALENTA, J., et al. *Biomechanika*. Praha: Academia, 1985. 539 s.

Seznam obrázků

OBR. 1 – PRINCIP DOPPLEROVA JEVU	13
OBR. 2 – ROZMĚŘENÍ SIGNÁLU AVG.....	15
OBR. 3 – PRŮMĚRNÉ HODNOTY PI A TT ZDRAVÝCH MLADÝCH PROBANDŮ	16
OBR. 4 – BIOLOGICKÝ MODEL NEURONU	25
OBR. 5 – SCHÉMA ANALOGIE BIOLOGICKÉHO A UMĚLÉHO NEURONU.....	25
OBR. 6 – PRŮBĚHY VYBRANÝCH AKTIVAČNÍCH FUNKCÍ	28
OBR. 7 – STRUKTURA VÍCEVRSTVÉ PERCEPTRONOVÉ SÍTĚ.....	29
OBR. 8 – PRŮBĚHY AVG SIGNÁLŮ POŘÍZENÝCH SYSTÉMEM IMEXLAB 9000.....	32
OBR. 9 – PODOBA PROGRAMU AVG IMEX	33
OBR. 10 – OVĚŘENÍ NORMALITY SOUBORU TESTOVACÍ MNOŽINY AF (A. FEMORALIS)....	37
OBR. 11 – OVĚŘENÍ NORMALITY SOUBORU TESTOVACÍ MNOŽINY AP (A. POPLITEA)	38
OBR. 12 – OVĚŘENÍ NORMALITY SOUBORU TESTOVACÍ MNOŽINY ATP (A. TIBIALIS POSTERIOR)	38
OBR. 13 – PROGRAM CLUSTERING, VÝSLEDKY KLASIFIKACE MNOŽINY LEG.....	41
OBR. 14 – PRŮBĚH ENERGIE SÍTĚ BĚHEM UČENÍ NA TRÉNOVACÍ MNOŽINĚ AF	43
OBR. 15 – PROGRAM NN, VÝSLEDKY KLASIFIKACE MNOŽINY ATP.....	44
OBR. 16 – MODUL PACIENTSKÁ DATA ZOBRAZUJÍCÍ ÚDAJE Z VYŠETŘENÍ.....	46

Použité zkratky a symboly

a_j	hlavní komponenta,
A	zrychlení systolické vlny [$m.s^{-2}$],
AF	arteria femoralis (tepna stehenní),
AP	arteria poplitea (tepna podkolenní),
ATP	arteria tibialis posterior (tepna holenní zadní),
AVG	arteriovelocitogram, signál časové změny střední rychlosti toku krve,
b_1, b_2	jednorozměrná charakteristika šikmosti a špičatosti výběrového rozdělení,
B_1, B_2	vícerozměrná charakteristika šikmosti a špičatosti výběrového rozdělení,
BP, BPI	tlak krve (blood pressure), tlakový index,
c	průměrná rychlost šíření ultrazvuku ve tkáních [$m.s^{-1}$],
D	zpomalení systolické vlny [$m.s^{-2}$],
DF	útlumový faktor,
EKG	signál elektrické aktivity srdce,
f_d	dopplerovský frekvenční zdvih [Hz],
f_v	frekvence vysílané nosné vlny [kHz],
$f(y_a)$	aktivační funkce neuronu,
K	testové kritérium testu normality,
LEG	označení množiny signálů z celé dolní končetiny,
n	normálový vektor,
NPI	normovaný pulsační index,
p	počet parametrů vektoru pozorování, tlak [Pa],
PPI	Pourcelotův index,
Re	Reynoldsovo číslo.
S	výběrová kovarianční matice,
SBI	Kasamův spektrální index širokopásmovosti,
ST	stenóza [%],
t_a, T_a	doba zrychlení [s],
t_0, T_0	časový interval mezi R vlnou EKG a patou AVG signálu [s],
t_{SD}, T_{SD}	časový interval mezi vrcholy systolické a diastolické vlny AVG [s],
T_1, T_n	testové kritérium Grubbsova testu,
v_j	vlastní vektor matice S ,
v	vektor střední rychlosti toku krve během periody [$m.s^{-1}$],
VT	index rychlost – čas [$m.s^{-2}$],
w_n	váhy neuronů,
x	sloupcový vektor pozorování,
\bar{x}	střední hodnota, průměr,
x_n	vstupy neuronů,
y_a	agregační funkce neuronu,
y_n	výstup neuronu,
α	úhel osy cévy a sondy [$^\circ$], frekvenční parametr,
β_1, β_2	charakteristiky šikmosti a špičatosti základního souboru,
γ	parametr úměrný perifernímu odporu řečiště,
λ	vlastní číslo matice,
σ^2	směrodatná odchylka výběru,
ν	kinetická viskozita krve [$m^2.s^{-1}$],
ω	úhlová frekvence [$rad.s^{-1}$],
Θ	práh neuronu.

Přílohy



Příloha A -Struktura souboru AVG.DBF

Pořadí	Název	Typ	Popis
1	ID_PAC	N(3)	Identifikátor záznamu pacienta
2	PRIJMENI	C(15)	Příjmení pacienta
3	DATUM	D(8)	Datum měření
4	CAS	C(8)	Čas měření
5	STRANA	C(3)	Měřená strana (SIN, DX)
6	MISTO	C(3)	Místo měření (AF, AIE, AP, ATP, ATA; FEM, TIB)
7	FMAX	N(7,3)	Maximální dopplerovská frekvence v kHz
8	FMIN	N(7,3)	Minimální dopplerovská frekvence v kHz
9	FMEAN	N(7,3)	Střední dopplerovská frekvence v kHz
10	A	N(7,3)	Zrychlení krevního toku v kHz/sec
11	D	N(7,3)	Zpomalení krevního toku v kHz/sec
12	T0	N(6,2)	Doba počátku pulsu od R vrcholu EKG v msec
13	TPER	N(7,2)	Doba trvání srdeční periody v msec
14	TEP	N(5,1)	Tepová frekvence v pulsech za minutu
15	PI	N(7,3)	Pulsační index
16	FDOPP	C(1)	Frekvence dopplerovské sondy v MHz (5, 8)
17	DRUHZAzn	C(2)	Druh záznamu (ME, PR, OD, VK)
18	PORPOC	N(2)	Pořadí pulsu(pro ME) / Počet pulsů (pro PR,OD,VK)



Příloha B - Struktura souboru PAC.DBF

Pořadí	Název	Typ	Popis
1	ID	N(3)	Interní identifikátor záznamu vyšetření pacienta
2	PRIJMENI	C(15)	Příjmení pacienta
3	JMENO	C(15)	Jméno pacienta
4	PACCISLO	C(10)	Rodné číslo pacienta
5	DATUMNAR	D(8)	Datum narození pacienta
6	VEK	N(3)	Věk pacienta v letech
7	VYSKA	N(3)	Výška pacienta v cm
8	VAHA	N(3)	Váha pacienta v kg
9	POHLAVI	C(1)	Pohlaví pacienta (M, Z)
10	DATUMMER	D(8)	Datum vyšetření
11	DIABETES	L(1)	Příznak diabetu
12	DIABETLET	N(2)	Počet let trvání diabetu
13	HYPERTENZE	L(1)	Příznak hypertenze
14	HYPERTLET	N(2)	Počet let hypertenze
15	GENZATEZ	L(1)	Příznak genetické zátěže
16	CEVNIOPER	L(1)	Příznak provedení cévní operace
17	SRDECNEMOC	L(1)	Příznak srdečního onemocnění
18	ANGINAPEKT	L(1)	Příznak anginy pectoris
19	VARIXY	L(1)	Příznak varixů
20	KOURENI	L(1)	Příznak kouření
21	KOURENILET	N(2)	Doba kouření v letech
22	KOUREKOLIK	N(3,1)	Počet cigaret denně
23	KLAUDIKSIN	L(1)	Příznak klaudikace vlevo
24	KLVZDALSIN	N(3)	Klaudikační vzdálenost v metrech pro levou nohu
25	KLAUDIKDEX	L(1)	Příznak klaudikace vpravo
26	KLVZDALDEX	N(3)	Klaudikační vzdálenost v metrech pro pravou nohu
27	STENOZASIN	N(3)	Velikost stenózy v procentech vlevo
28	STENOZADDEX	N(3)	Velikost stenózy v procentech vpravo
29	TK_AB	N(3)	Systolický krevní tlak na paži
30	TK_AP_DX	N(3)	Krevní tlak na AP DX
31	TK_ATP_DX	N(3)	Krevní tlak na ATP DX
32	TK_ATA_DX	N(3)	Krevní tlak na ATA DX
33	TK_AP_SIN	N(3)	Krevní tlak na AP SIN
34	TK_ATP_SIN	N(3)	Krevní tlak na ATP SIN
35	TK_ATA_SIN	N(3)	Krevní tlak na ATA SIN
36	TEPL_DX	N(4,1)	Teplota pravé nohy
37	TEPL_SIN	N(4,1)	Teplota levé nohy



Příloha C - Klasifikace užitím shlukové analýzy (množiny AF, AP, ATP, LEG)





Příloha C - Klasifikace užitím shlukové analýzy





Příloha D -Klasifikace množiny AF užitím neuronových sítí (topologie T1-T4)





Příloha D - Klasifikace množiny AF užitím neuronových sítí (topologie T1-T4)





Příloha E - Klasifikace množiny AP užitím neuronových sítí (topologie T1-T4)





Příloha E - Klasifikace množiny AP užitím neuronových sítí (topologie T1-T4)





Příloha F - Klasifikace množiny ATP užitím neuronových sítí (topologie T1-T4)





Příloha F - Klasifikace množiny ATP užitím neuronových sítí (topologie T1-T4)



Příloha G -Klasifikace množiny LEG užitím neuronových sítí (topologie T5-T8)



Příloha G - Klasifikace množiny LEG užitím neuronových sítí (topologie T5-T8)



Příloha H -Výsledky klasifikací jednotlivých množin použitých metod

ID	Str	Zař	AF					AP					ATP					LEG				
			C	T1	T2	T3	T4	C	T1	T2	T3	T4	C	T1	T2	T3	T4	C	T5	T6	T7	T8
42	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
42	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
43	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
43	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
44	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
44	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
45	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
45	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
46	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
46	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
47	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
47	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
48	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
48	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
49	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
49	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
50	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
50	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
51	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
51	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
52	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
52	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
53	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
53	L	1	-	-	-	-	-	1	1	1	1	1	1	1	1	1	1	-	-	-	-	-
54	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
54	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
55	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
55	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
56	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
56	L	1	1	1	1	1	1	-	-	-	-	-	1	1	1	1	1	-	-	-	-	-
57	R	1	-	-	-	-	-	-	-	-	-	-	1	1	1	1	1	-	-	-	-	-
57	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
58	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
58	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
59	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
59	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
66	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
66	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	2	1	1	1	1	1	1
67	R	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
67	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
68	R	1	1	1	1	1	1	-	-	-	-	-	1	1	1	1	1	-	-	-	-	-
68	L	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1

Příloha H - Výsledky klasifikací jednotlivých množin použitých metod

ID	Str	Zař	AF					AP					ATP					LEG				
			C	T1	T2	T3	T4	C	T1	T2	T3	T4	C	T1	T2	T3	T4	C	T5	T6	T7	T8
69	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	3	2	2	2	2	2	2
69	L	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
70	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
70	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
71	R	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	2	3	3	3	3	3
71	L	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
72	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
72	L	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
73	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
73	L	2	2	2	2	2	2	2	2	2	2	2	2	2	3	3	3	2	2	2	2	2
74	R	2	-	-	-	-	-	2	2	2	2	2	2	2	2	2	2	-	-	-	-	-
74	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
75	R	2	2	3	2	2	2	2	3	3	2	3	2	2	2	3	2	3	2	2	2	2
75	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
76	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
76	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
77	R	2	2	2	2	2	2	2	2	3	3	2	2	2	2	2	2	2	1	3	3	3
77	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	3	2	2	2	2	2	2
78	R	2	-	-	-	-	-	2	2	2	2	3	3	2	2	2	2	-	-	-	-	-
78	L	2	2	2	2	2	2	2	2	2	2	2	2	2	3	3	3	2	2	2	2	2
79	R	2	-	-	-	-	-	2	2	2	2	2	2	2	2	2	2	-	-	-	-	-
79	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
80	R	3	-	-	-	-	-	3	3	3	3	3	3	3	3	3	3	-	-	-	-	-
80	L	2	-	-	-	-	-	2	2	2	2	2	2	2	2	2	2	-	-	-	-	-
81	R	2	-	-	-	-	-	2	2	2	2	2	2	2	2	2	2	-	-	-	-	-
81	L	2	-	-	-	-	-	-	-	-	-	-	2	2	2	2	2	-	-	-	-	-
82	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
82	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
83	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
83	L	3	3	3	3	2	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
85	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
85	L	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
86	R	2	3	2	2	2	2	3	2	3	2	2	2	3	2	3	3	2	2	2	3	3
86	L	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
87	R	3	2	3	2	3	3	2	1	3	1	1	-	-	-	-	-	-	-	-	-	-
87	L	2	2	2	2	2	2	1	1	1	1	1	2	1	1	2	2	1	1	1	3	2
88	R	3	3	3	2	3	2	3	2	2	3	2	3	3	2	3	3	2	2	3	3	3
88	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
89	R	3	2	2	2	2	2	2	2	3	2	2	3	2	2	2	2	2	2	2	2	2
89	L	2	2	2	2	2	2	-	-	-	-	-	2	2	2	2	2	-	-	-	-	-
90	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
90	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2

Příloha H - Výsledky klasifikací jednotlivých množin použitých metod

ID	Str	Zař	AF					AP					ATP					LEG				
			C	T1	T2	T3	T4	C	T1	T2	T3	T4	C	T1	T2	T3	T4	C	T5	T6	T7	T8
92	R	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
92	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
93	R	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
93	L	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
95	R	2	-	-	-	-	-	2	2	2	2	2	-	-	-	-	-	-	-	-	-	-
95	L	2	2	2	2	2	2	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
96	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	3	2	2	2	1
96	L	2	2	3	2	2	2	2	2	2	3	2	3	2	2	2	3	2	3	2	2	2
97	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
97	L	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
99	R	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
99	L	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
100	R	2	-	-	-	-	-	2	2	2	2	2	2	2	2	2	2	-	-	-	-	-
100	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
101	R	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
101	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
102	R	2	2	3	3	3	3	3	3	3	2	2	2	2	2	2	3	2	2	3	3	3
102	L	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
103	R	3	-	-	-	-	-	3	3	3	2	3	-	-	-	-	-	-	-	-	-	-
103	L	2	3	2	2	3	2	2	3	3	2	2	-	-	-	-	-	-	-	-	-	-
104	R	2	2	2	2	3	2	3	3	3	3	3	2	2	2	2	3	3	3	3	3	3
104	L	3	3	3	3	3	3	-	-	-	-	-	3	3	3	3	3	-	-	-	-	-
105	R	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
105	L	3	3	3	3	3	3	3	3	3	3	3	-	-	-	-	-	-	-	-	-	-
106	R	2	2	2	2	2	2	2	2	2	2	2	2	2	3	2	3	2	2	2	2	2
106	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
109	R	2	2	2	3	2	2	3	2	2	2	2	2	2	2	2	2	2	2	3	2	2
109	L	2	2	2	3	2	3	3	2	3	2	3	3	2	3	2	2	2	2	2	3	2
110	R	2	-	-	-	-	-	2	3	1	1	2	3	2	3	2	3	-	-	-	-	-
110	L	2	2	1	3	2	1	2	2	2	1	1	2	2	1	2	1	2	1	1	1	2
111	L	2	2	2	2	1	2	2	2	3	2	2	2	2	2	2	2	2	1	1	1	1
112	R	3	1	1	1	1	1	2	3	3	3	3	2	2	3	2	2	3	2	1	2	1
112	L	3	2	2	2	2	1	2	3	3	3	2	3	2	3	3	3	2	2	3	2	2
113	R	2	3	3	2	3	3	2	2	2	3	1	3	3	2	2	3	2	2	3	2	3
113	L	3	-	-	-	-	-	2	2	3	2	2	2	3	3	3	3	-	-	-	-	-
114	L	3	3	3	3	3	3	3	2	3	2	3	3	3	3	3	3	3	3	2	3	3
115	R	2	1	2	2	3	2	-	-	-	-	-	2	2	3	3	2	-	-	-	-	-
115	L	2	2	2	2	2	2	1	3	1	3	2	1	2	3	2	2	1	2	3	2	3
116	R	2	2	3	2	2	2	3	2	3	2	2	3	2	2	3	3	2	2	3	3	3
116	L	2	1	1	2	2	1	2	2	3	2	2	3	3	3	3	3	3	2	1	2	2
117	R	2	2	2	2	2	2	2	2	2	2	1	-	-	-	-	-	-	-	-	-	-
117	L	2	2	2	2	2	2	2	2	3	2	2	2	2	2	2	2	2	1	2	2	2

Příloha H - Výsledky klasifikací jednotlivých množin použitých metod

ID	Str	Zař	AF					AP					ATP					LEG				
			C	T1	T2	T3	T4	C	T1	T2	T3	T4	C	T1	T2	T3	T4	C	T5	T6	T7	T8
118	R	2	3	2	3	3	2	2	3	2	3	2	3	2	3	1	2	3	3	2	3	3
119	R	3	1	3	3	1	2	3	3	3	3	3	3	3	3	3	3	2	3	2	2	2
119	L	3	2	3	2	2	3	3	3	2	3	2	3	2	3	3	3	3	3	3	3	3
120	R	3	2	3	3	3	3	2	3	2	3	3	2	3	3	3	3	2	3	2	2	2
120	L	3	2	2	2	2	2	2	3	2	3	2	3	2	3	2	2	3	2	2	2	3
121	R	2	-	-	-	-	-	2	2	2	2	2	1	2	2	2	1	-	-	-	-	-
121	L	2	1	1	3	2	1	3	2	1	2	2	3	2	3	2	3	2	2	3	2	3
122	R	2	-	-	-	-	-	2	2	2	2	2	2	2	2	2	2	-	-	-	-	-
122	L	2	2	2	2	2	3	2	2	2	2	2	2	3	2	2	2	2	2	2	2	3
123	R	3	3	2	3	3	3	2	2	2	3	2	2	2	3	3	2	3	2	3	3	3
123	L	3	2	2	2	2	3	2	3	3	2	2	3	2	2	2	3	3	2	3	2	2
124	R	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	1
125	R	2	2	2	3	3	2	2	2	2	2	1	2	2	2	2	2	2	2	2	2	2
125	L	3	2	2	2	2	2	3	3	2	3	2	2	3	3	2	3	3	3	3	3	3
126	R	3	3	2	3	2	3	3	3	3	3	3	2	3	2	2	3	3	2	2	2	3
126	L	3	2	2	2	2	2	3	3	3	3	3	2	3	3	3	3	3	3	2	3	3
127	R	3	3	3	3	3	2	3	3	3	3	3	3	3	3	3	3	2	3	3	3	3
127	L	3	3	2	2	2	2	3	3	3	3	3	2	2	2	1	2	2	3	3	3	3
128	L	3	-	-	-	-	-	2	2	3	2	2	3	3	3	3	3	-	-	-	-	-
129	R	3	2	2	2	2	2	2	2	2	2	2	3	2	3	2	2	2	2	2	2	3
129	L	2	2	3	2	2	2	2	3	3	2	2	2	2	2	2	3	2	2	3	3	2
130	R	2	2	2	2	2	2	2	2	2	2	2	3	2	2	1	2	2	2	2	2	2
130	L	2	2	2	2	2	2	2	1	2	2	2	1	2	2	2	2	2	2	1	2	1
131	L	2	2	2	2	2	1	2	2	3	2	2	2	2	2	2	3	3	2	1	1	2
132	R	2	2	2	2	2	2	2	2	2	2	2	2	2	3	2	2	2	2	2	2	2
132	L	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	3
133	R	3	2	2	2	2	2	-	-	-	-	-	3	2	3	3	3	-	-	-	-	-
133	L	2	3	2	2	2	2	2	3	2	3	3	2	2	2	2	2	3	3	3	3	2